Universität Münster

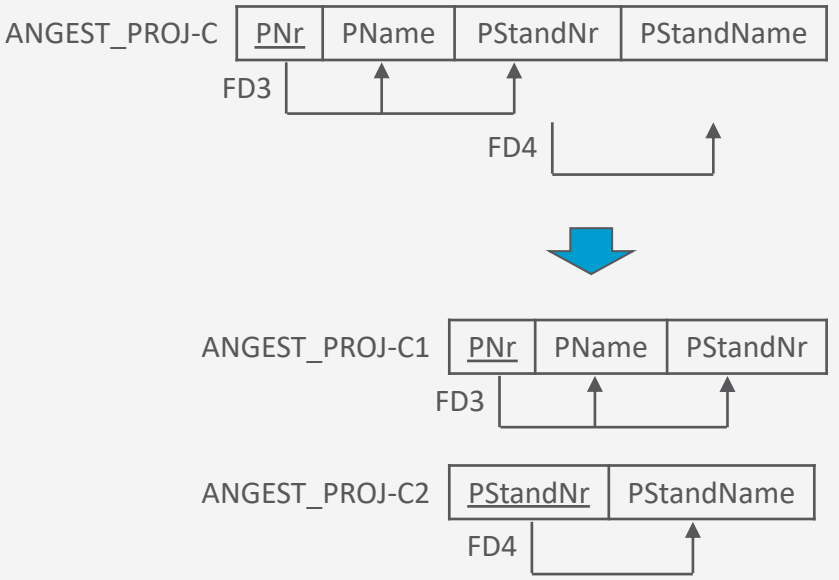

Relationale Entwurfstheorie

Datenbanken

wissen.leben

Tanya Braun
Arbeitsgruppe Data Science, Institut für Informatik

Inhalte: Datenbanken (DBs)

1. **Einführung**
   - Anwendungen
   - Datenbankmanagementsysteme
2. **Datenbank-Modellierung**
   - Entity-Relationship-Modell (ER-Modell)
   - Beziehung zwischen ER und UML
3. **Das relationale Modell**
   - Relationales Datenmodell (RM)
   - Vom ER-Modell zum RM
   - Relationale Algebra als Anfragesprache
4. **Relationale Entwurfstheorie**
   - Funktionale Abhängigkeiten
   - Normalformen
5. **Structured Query Language (SQL)**
   - Datendefinition
   - Datenmanipulation
6. **Anfrageverarbeitung**
   - Architektur
   - Indexierung
   - Anfragepläne, Optimierung
7. **Transaktionen**
   - Transaktionsverarbeitung, Schedules, Sperren
   - Wiederherstellung
8. **Verteilte Datenbanken**
   - Fragmentierung, Replikation, Allokation; CAP
   - Anfragebeantwortung, föderierte Systeme

Phasen des DB-Entwurfs

- Ausblick: Von der Anwendung her
  - Teil von 2. DB-Modellierung
    - Methode: ERM
  - Teil von 3. Das relationale Datenmodell
    - Methode: relationale Modellierung
  - Teil von 4. DB-Entwurf
  - Teil von 5. SQL & Übergang zu „Hinter den Kulissen“

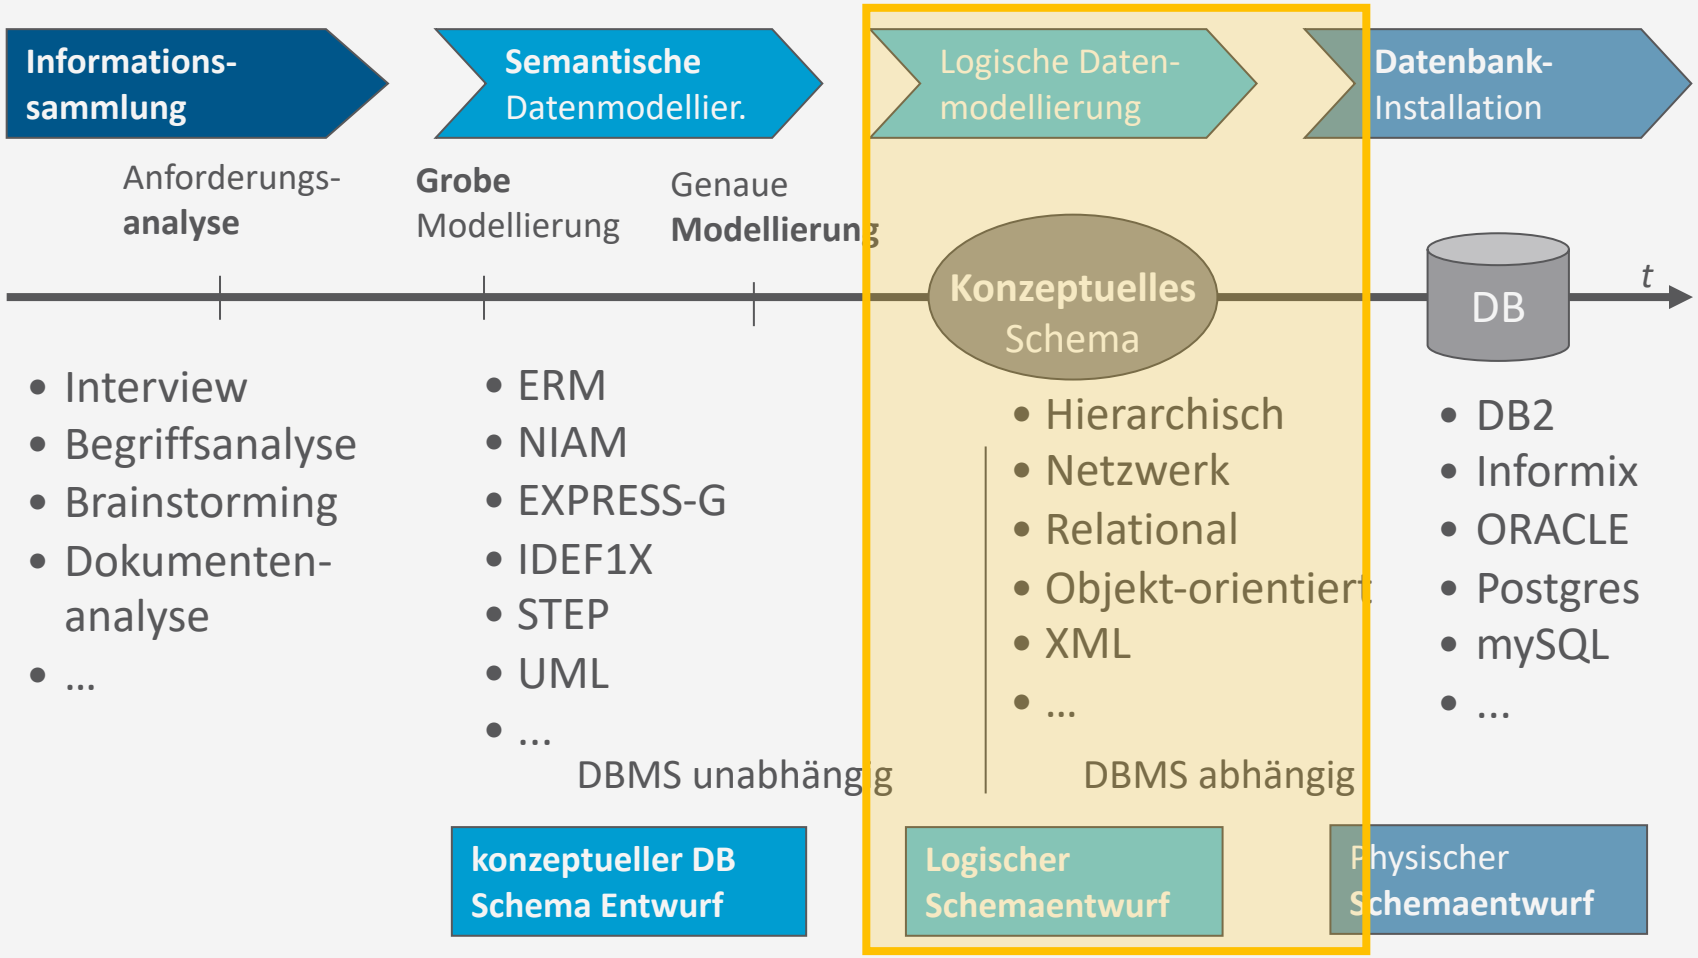

„Schlechte“ Relation

AName	SVNr	Geb	Adr	AbtNr	Abt	ALeitSVNr
Smith, John B.	123456789	1965-01-09	731 Fondren, Houston TX	5	Research	333445555
Wong, Franklin T.	333445555	1955-12-08	638 Voss, Houston TX	5	Research	333445555
Zelaya, Alicia J.	999887777	1968-07-19	3321 Castle,Spring, TX	4	Administration	987654321
Wallace, Jennifer S.	987654321	1941-06-20	291, Berry, Bellaire, TX	4	Administration	987654321
Narayan, Ramesh K.	666884444	1962-09-15	975, FireOak, Humble, TX	5	Research	333445555
English, Joyce A.	453453453	1972-07-31	Rice, Houston, TX	5	Research	333445555
Jabber, Ahmad V.	987987987	1969-03-29	Dallas, Houston, TX	4	Administration	987654321
Borg, James E.	888665555	1937-11-10	Stone, Houston, TX	1	Headquarters	888665555

„Schlechte“ Relation: Einfügeanomalie

AName	SVNr	Geb	Adr	AbtNr	Abt	ALeitSVNr
Smith, John B.	123456789	1965-01-09	731 Fondren, Houston TX	5	Research	333445555
Wong, Franklin T.	333445555	1955-12-08	638 Voss, Houston TX	5	Research	333445555
Zelaya, Alicia J.	999887777	1968-07-19	3321 Castle,Spring, TX	4	Administration	987654321
Wallace, Jennifer S.	987654321	1941-06-20	291, Berry, Bellaire, TX	4	Administration	987654321
Narayan, Ramesh K.	666884444	1962-09-15	975, FireOak, Humble, TX	5	Research	333445555
English, Joyce A.	453453453	1972-07-31	Rice, Houston, TX	5	Research	333445555
Jabber, Ahmad V.	987987987					87654321
Borg, James E.	888665555	1937-11-10	Stone, Houston, TX	1	Headquarters	888665555
Grawunder, M	007	1971-02-17	Barßel	1	Hädquarters	886665554
				42	Geheim	007

neuer Angestellter → Information zu Abteilung (konsistent?) → Tippfehler?

keine neue Abteilung ohne Mitarbeiter

„Schlechte“ Relation: Update-Anomalie

AName	SVNr	Geb	Adr	AbtNr	Abt	ALeitSVNr
Smith, John B.	123456789	1965-01-09	731 Fondren, Houston TX	5	Research	732456732
Wong, Franklin T.	333445555	1955-12-08	638 Voss, Houston TX	5	Research	732456732
Zelaya, Alicia J.	999887777	1968-07-19	3321 Castle,Spring, TX	4	Administration	987654321
Wallace, Jennifer S.	987654321	1941-06-20	291, Berry, Bellaire, TX	4	Administration	987654321
Narayan, Ramesh K.	666884444	1962-09-15	975, FireOak, Humble, TX	5	Research	333445555
English, Joyce A.	453453453	1972-07-31	Rice, Houston, TX	5	Research	732456732
Jabber, Ahmad V.	987987987	1969-03-29	Dallas, Houston, TX	4	Administration	987654321
Borg, James E.	888665555	1937-11-10	Stone, Houston, TX	1	Headquarters	888665555

Abteilung Research bekommt neuen Leiter ... hoffentlich keine Zeile vergessen

„Schlechte“ Relation: Löschanomalie

AName	SVNr	Geb	Adr	AbtNr	Abt	ALeitSVNr
Smith, John B.	123456789	1965-01-09	731 Fondren, Houston TX	5	Research	333445555
Wong, Franklin T.	333445555	1955-12-08	638 Voss, Houston TX	5	Research	333445555
Zelaya, Alicia J.	999887777	1968-07-19	3321 Castle,Spring, TX	4	Administration	987654321
Wallace, Jennifer S.	987654321	1941-06-20	291, Berry, Bellaire, TX	4	Administration	987654321
Narayan, Ramesh K.	666884444	1962-09-15	975, FireOak, Humble, TX	5	Research	333445555
English, Joyce A.	453453453	1972-07-31	Rice, Houston, TX	5	Research	333445555
Jabber, Ahmad V.	987987987	1969-03-29	Dallas, Houston, TX	4	Administration	987654321
~~Borg, James E.~~	~~888665555~~	~~1937-11-10~~	~~Stone, Houston, TX~~	~~1~~	~~Headquarters~~	~~888665555~~

James E. Borg geht in den Ruhestand. Es gibt aber noch keinen Nachfolger ... Wo ist die Abteilung Headquarters hin??

„Schlechte“ Relation

- Problem: Kombination aus Angestellten- mit Abteilungsinformation
- Einfüge-Anomalie
  - Neuer Angestellter → Information zu Abteilung konsistent?
  - Keine neue Abteilung ohne Mitarbeiter
- Update-Anomalie
  - Änderung des Abteilungsleiters → Update in allen Angestellten-Einträgen?
- Lösch-Anomalie
  - Letzter Angestellter einer Abteilung gelöscht → Abteilung verschwindet

- Was fällt auf?
  - Es tauchen Redundanzen in den Tupeln auf
  - Verschiedene Abhängigkeiten in der Relation
  - Änderungen an den Daten können zu Anomalien führen, da
    - Informationen an mehreren Stellen verändert werden müssen
    - Abhängigkeiten nicht berücksichtigt werden

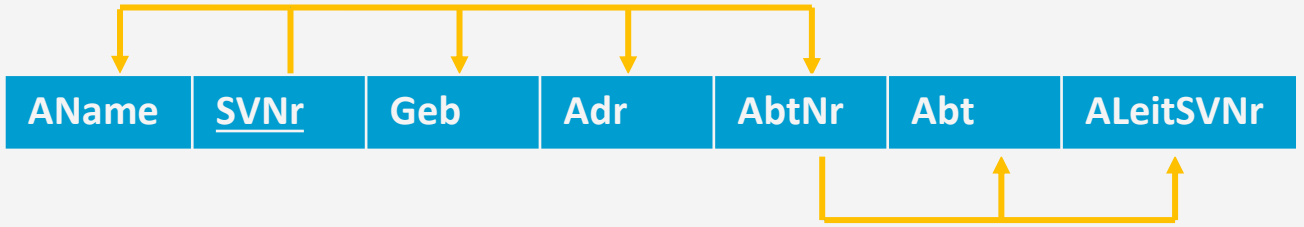

Ziele der relationalen Entwurfstheorie

- Bewertung der Qualität eines Relationenschemas
  - Redundanz
    - Viel Redundanz erhöht Gefahr für Anomalien, vor allem bei Updates
  - Einhaltung von Konsistenzbedingungen
    - Funktionale Abhängigkeiten, anhand derer Konsistenz geprüft werden kann
- Normalformen als Gütekriterium
- Gegebenenfalls Verbesserung eines Relationenschemas durch
  - Synthesealgorithmus
  - Zerlegungsalgorithmus

- Meist gute Qualität bei aus validen ER-Diagrammen erstellten DB-Schemata

Überblick: 4. Datenbankentwurf

A. Funktionale Abhängigkeiten

- Definition, Schlüssel, Ableitungen
- Attributhülle, kanonische Überdeckung

B. Normalformen

- Zerlegung von Relationen
- Exkurs: NF^2; 1NF, 2NF, 3NF, BCNF, 4NF, 5NF
- Synthesealgorithmus, Zerlegungsalgorithmus

C. Datenqualität

- Datenqualitätsprobleme, Dimensionen der Datenqualität

Funktionale Abhängigkeiten

- $R(A_1, \ldots, A_n)$ sei ein Schema, α und β seien Attributteilmengen von R
- FD: $\alpha \rightarrow \beta$ sei eine funktionale Abhängigkeit (*functional dependency*), genau dann wenn

$$\forall t_1, t_2 \in r(R) : \text{Wenn } t_1[\alpha] = t_2[\alpha] \text{ gilt, gilt auch } t_1[\beta] = t_2[\beta]$$

  - D.h., Werte von α bestimmen eindeutig Werte von β
  - FD heißt *trivial*, wenn $\beta \subseteq \alpha$
  - Für ANGEST_ABT gilt:
    - F1: $\{SVNr\} \rightarrow \{AName, Geb, Adr, AbtNr\}$
    - F2: $\{AbtNr\} \rightarrow \{Abt, ALeitSVNr\}$
    - Relationen abgeleitet aus ER-Modell
- Wenn α ein Schlüssel ist, dann gilt $\alpha \rightarrow \beta$ für alle möglichen β aus R

Folgt aus $\alpha \rightarrow \beta$ auch $\beta \rightarrow \alpha$?

Was ist, wenn α ein Schlüssel ist?

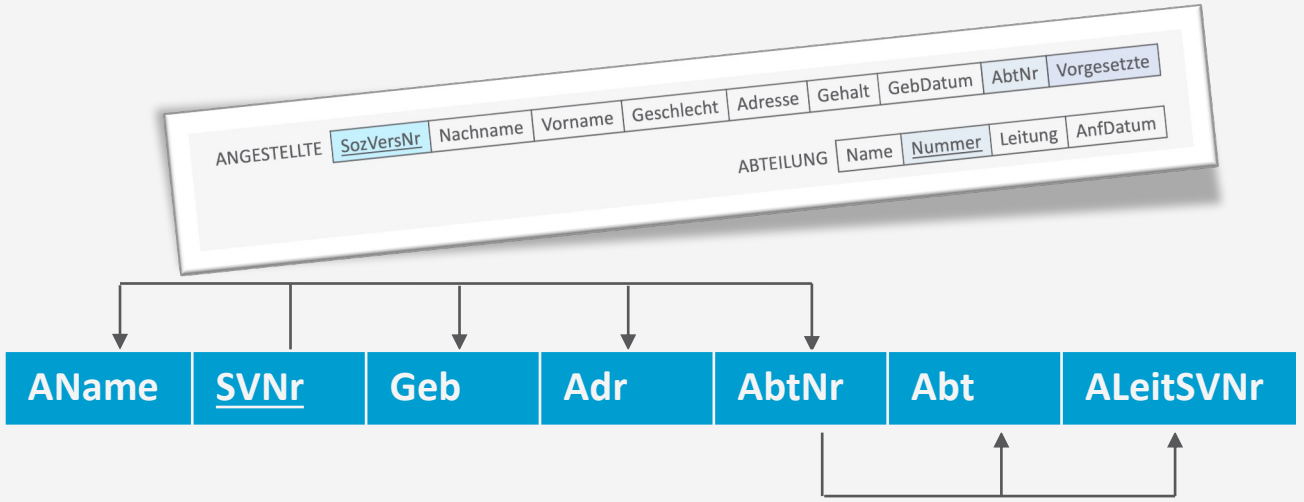

Funktionale Abhängigkeiten

- Für ANGEST_PROJ gilt
  - F3: $\{SVNr, PNr\} \rightarrow \{Std\}$
  - F4: $\{SVNr\} \rightarrow \{AName\}$
  - F5: $\{PNr\} \rightarrow \{PName, PStandort\}$
  - Relationen abgeleitet aus ER-Modell:

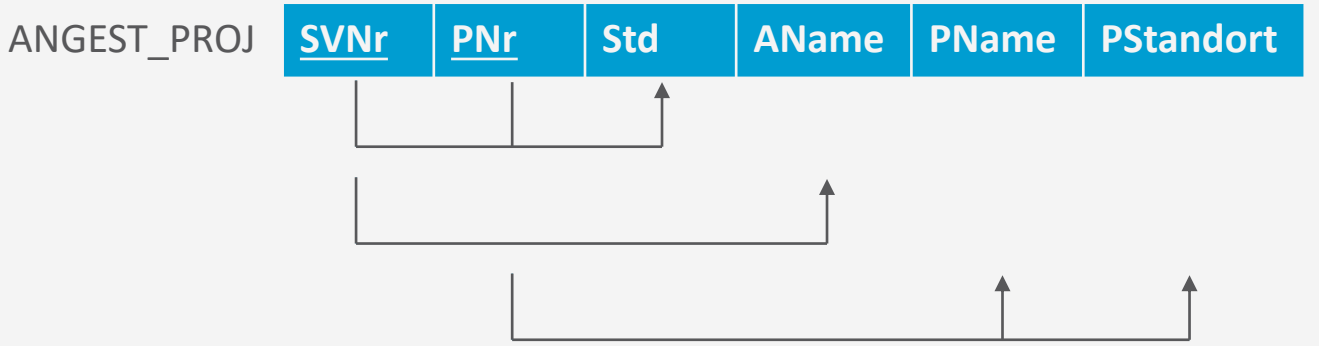

ANGESTELLTE	SozVersNr	Nachname	Vorname	Geschlecht	Adresse	Gehalt	GebDatum	AbtNr	Vorgesetzte

ARBEITET_AN	ProjNr	SozVersNr	Stunden

PROJEKT	Nummer	Name	Standort	AbtNr

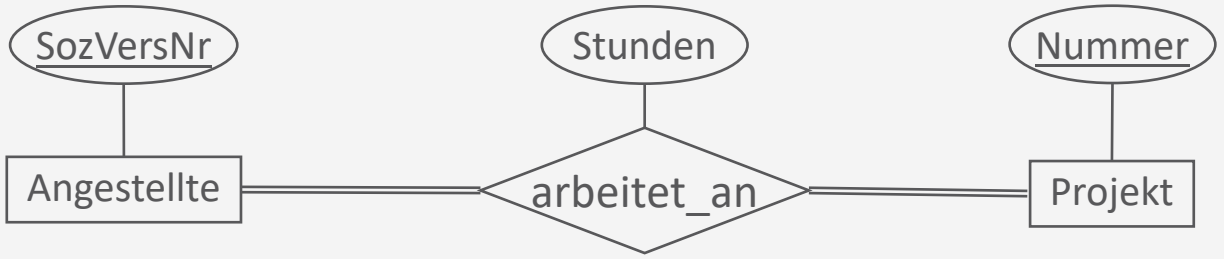

Wo kommen die FDs her?

- Können die nicht einfach aus den Daten abgeleitet werden?
- Beispiel: Tierart → Farbe?

Datum	Tierart	Farbe
12.3.2010	Schwan	weiß
14.3.2010	Fuchs	rot
17.3.2010	Schwan	weiß

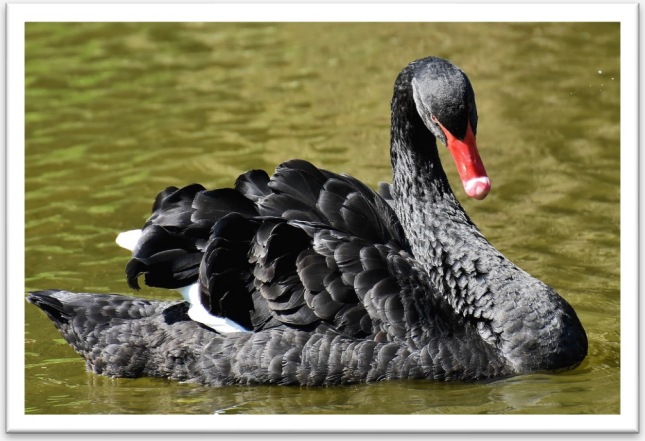

"Not all swans are white."

- FDs können nicht aus den Daten (Extension) abgeleitet werden
- FDs sind Eigenschaften des Relationenschemas (Intension)
- Sie müssen vom DB-Designer definiert werden

Schlüssel

- $\alpha \subseteq R$ ist ein Superschlüssel, falls gilt:
  - $\alpha \rightarrow R$
- β ist voll funktional abhängig von α genau dann, wenn gilt
  - $\alpha \rightarrow \beta$ und
  - α kann nicht mehr verkleinert werden (α minimal), d.h.
    - $\forall A \in \alpha$ folgt, dass $(\alpha - \{A\}) \rightarrow \beta$ nicht gilt, oder kürzer
    - $\forall A \in \alpha : \neg\big((\alpha - \{A\}) \rightarrow \beta\big)$
  - Notation für volle funktionale Abhängigkeit: $\alpha \rightarrow^* \beta$
- $\alpha \subseteq R$ ist ein Schlüsselkandidat, falls gilt:
  - $\alpha \rightarrow^* R$

Schlüssel: Beispiel 1

- Beispiel: Für ANGEST_ABT gelten $F = \{F1, F2\}$
  - F1: $\{SVNr\} \rightarrow \{AName, Geb, Adr, AbtNr\}$
  - F2: $\{AbtNr\} \rightarrow \{Abt, ALeitSVNr\}$
- $\{SVNr, AbtNr\} \rightarrow \{SVNr, AbtNr, AName, Geb, Adr, Abt, ALeitSVNr\}$
  - $\{SVNr, AbtNr\}$ ein Superschlüssel?
    - Ja, da alle Attribute eindeutig durch $\{SVNr, AbtNr\}$ bestimmt werden
  - $\{SVNr, AbtNr, AName, Geb, Adr, Abt, ALeitSVNr\}$ voll funktional abhängig von $\{SVNr, AbtNr\}$?
    - Nein, da $\{SVNr, AbtNr\}$ verkleinert werden kann: $\{SVNr\}$ reicht aus
  - $\{SVNr, AbtNr\}$ Schlüsselkandidat?
    - Nein, da volle funktionale Abhängigkeit nicht gilt

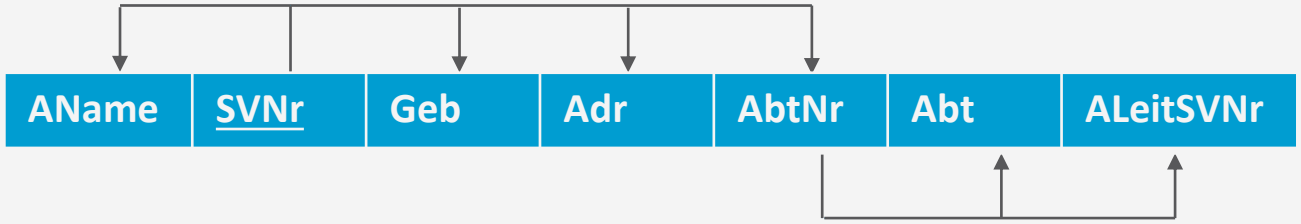

Schlüssel: Beispiel 2

- Für ANGEST_PROJ gilt
  - F3: $\{SVNr, PNr\} \rightarrow \{Std\}$
  - F4: $\{SVNr\} \rightarrow \{AName\}$
  - F5: $\{PNr\} \rightarrow \{PName, PStandort\}$
  - Volle funktionale Abhängigkeiten
    - $\{SVNr\} \rightarrow^* \{SVNr, AName\}$
      - Kein Superschlüssel, da z.B. Std nicht allein von $SVNr$ abhängig
    - $\{PNr\} \rightarrow^* \{PNr, PName, PStandort\}$
      - Kein Superschlüssel, da z.B. Std nicht allein von PNr abhängig
    - $\{SVNr, PNr\} \rightarrow^* \{SVNr, PNr, Std, AName, PName, PStandort\}$
      - Super- und Schlüsselkandidat, da $\{SVNr, PNr\} \rightarrow^{\cdot}$ ANGEST_PROJ

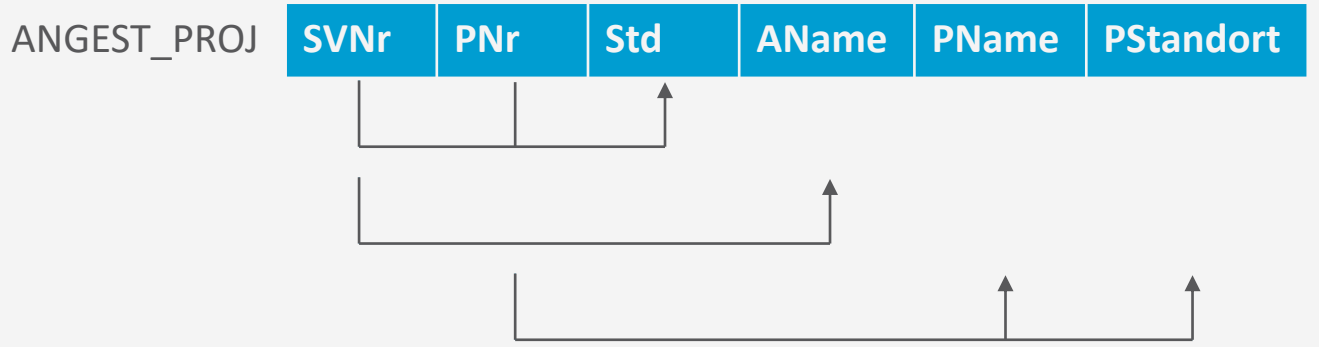

Wie sehen weitere Superschlüssel aus?

Wie sieht es mit deren voller funktionaler Abhängigkeit aus?

Herleitung funktionaler Abhängigkeiten

- Aus gegebenen FDs können weitere FDs abgeleitet werden
  - Mittels Inferenzregeln
- Transitive Hülle F^+:
  - Auch manchmal Abschluss (engl. *closure*) genannt
  - Gegeben eine Menge von FDs F
  - F^+: Menge aller FDs, die mit Inferenzregeln abgeleitet werden können

- Es gibt sechs Inferenzregeln (RATZAP)
  - *IR1*: **R**eflexivitätsregel
  - *IR2*: **A**ugmentationsregel
  - *IR3*: **T**ransivitätsregel
  - *IR4*: **Z**erlegungsregel
  - *IR5*: **A**dditive oder Vereinigungsregel
  - *IR6*: **P**seudotransitive Regel

IR1-3 auch unter Armstrong-Axiomen bekannt
- Vollständig: Erzeugen nur gültige FDs
- Korrekt: Jede mögliche FD lässt sich herleiten

IR4-6 lassen sich aus IR1-3 ableiten
- Erleichtern Ableitungen

Die sechs Inferenzregeln (RATZAP)

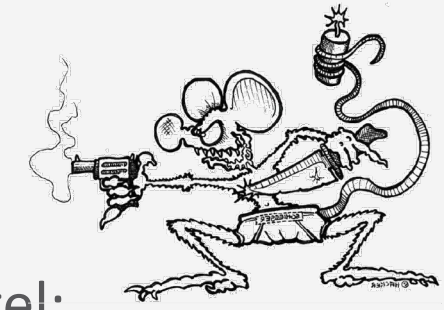

- **R**eflexivitätsregel:
  - *IR1*: Falls $Y \subseteq X$, dann $X \rightarrow Y$
  - Eine Attributmenge bestimmt sich immer selbst oder eine ihrer Teilmengen
- **A**ugmentationsregel:
  - *IR2*: Falls $X \rightarrow Y$, dann $XZ \rightarrow YZ$
  - Hinzufügen von Attributen auf beiden Seiten führt zu weiterer FD
- **T**ransitivitätsregel:
  - *IR3*: Falls $\{X \rightarrow Y, Y \rightarrow Z\}$, dann $X \rightarrow Z$
- **Z**erlegungsregel:
  - *IR4*: Falls $X \rightarrow YZ$, dann $X \rightarrow Y$ und $X \rightarrow Z$
  - Attribute auf der rechten Seite können entfernt und FDs in Teilmengen zerlegt werden
- **A**dditive oder Vereinigungsregel:
  - *IR5*: Falls $\{X \rightarrow Y, X \rightarrow Z\}$, dann $X \rightarrow YZ$
  - Gegenstück zu **Z** (*IR4*): Regel wieder zusammenfassen
- **P**seudotransitive Regel:
  - *IR6*: Falls $\{X \rightarrow Y, WY \rightarrow Z\}$, dann $WX \rightarrow Z$
  - Transitivität im Kontext

Beispiel für die Anwendung von Inferenzregeln

- Beispiel: $F = \{F1, F2\}$
  - F1: $\{SVNr\} \rightarrow \{AName, Geb, Adr, AbtNr\}$
  - F2: $\{AbtNr\} \rightarrow \{Abt, ALeitSVNr\}$
  - Zusätzlich können u.a. abgeleitet werden
    - F3: $\{SVNr\} \rightarrow \{Abt, ALeitSVNr\}$
      - IR3
    - F4: $\{SVNr\} \rightarrow \{Adr, AbtNr\}$
      - IR4
    - F5: $\{SVNr\} \rightarrow \{SVNr\}$
      - IR1

- Regeln
  - *IR1*: Falls $Y \subseteq X$, dann $X \rightarrow Y$
  - *IR2*: Falls $X \rightarrow Y$, dann $XZ \rightarrow YZ$
  - *IR3*: Falls $\{X \rightarrow Y, Y \rightarrow Z\}$, dann $X \rightarrow Z$
  - *IR4*: Falls $X \rightarrow YZ$, dann $X \rightarrow Y$ und $X \rightarrow Z$
  - *IR5*: Falls $\{X \rightarrow Y, X \rightarrow Z\}$, dann $X \rightarrow YZ$
  - *IR6*: Falls $\{X \rightarrow Y, WY \rightarrow Z\}$, dann $WX \rightarrow Z$

Was für FDs können abgeleitet werden?

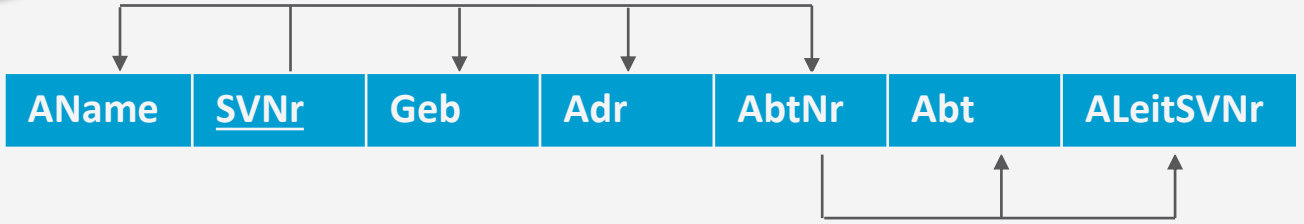

Attributhülle

- Attributhülle α^+ für eine Menge von Attributen α
  - Alle Attribute, die von α funktional abhängen
- Berechnung
  - Eingabe: Menge von FDs F, Menge von Attributen α
  - Ausgabe: Vollständige Menge von Attributen α^+, für die gilt: $\alpha \rightarrow \alpha^+$
  - Vorgehen:
    - Initialisierung: $\alpha^+ \leftarrow \alpha$
    - Für jede FD $\beta \rightarrow \gamma$ in F
      - Wenn β in α^+ vorkommt, dann füge γ zu α^+ hinzu
    - Gib α^+ aus

```
AttrHülle(F, α)
    α⁺ ← α
    while α⁺ geändert do
        for each β → γ ∈ F do
            if β ⊆ α⁺ then
                α⁺ ← α⁺ ∪ γ
    return α⁺
```

Attributhülle: Beispiel

- Für ANGEST_PROJ gilt
  - F3: $\{SVNr, PNr\} \rightarrow \{Std\}$
  - F4: $\{SVNr\} \rightarrow \{AName\}$
  - F5: $\{PNr\} \rightarrow \{PName, PStandort\}$

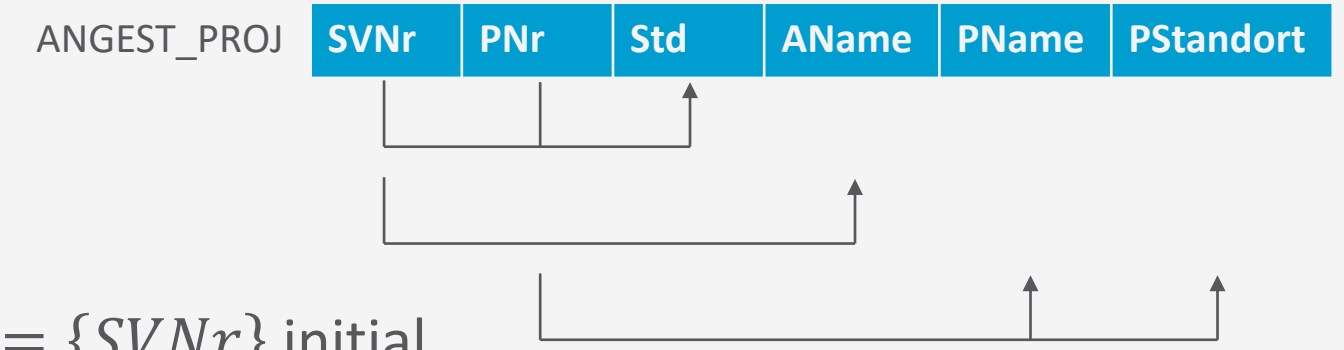

- Attributhülle $\alpha = \{SVNr\}$ mit $\alpha^+ = \alpha = \{SVNr\}$ initial
  - Betrachte F3, F4, F5:
    - Betrachte F3 mit $\beta = \{SVNr, PNr\}$: $\beta \not\subseteq \alpha^+$ (keine Änderung)
    - Betrachte F4 mit $\beta = \{SVNr\}$: $\beta \subseteq \alpha^+$, damit $\alpha^+ = \{SVNr, AName\}$
    - Betrachte F5 mit $\beta = \{PNr\}$: $\beta \not\subseteq \alpha^+$ (keine Änderung)
  - Änderung in α^+, also nochmal: Betrachte F3, F4, F5
    - Keine Änderung mehr in α^+
  - Ausgabe: $\alpha^+ = \{SVNr, AName\}$

ATTRHÜLLE(F, α)
  $\alpha^+ \leftarrow \alpha$
  while α^+ geändert **do**
    for each $\beta \rightarrow \gamma \in F$ **do**
      if $\beta \subseteq \alpha^+$ **then**
        $\alpha^+ \leftarrow \alpha^+ \cup \gamma$
  return α^+

Attributhülle: Beispiel

- F1: $\{SVNr\} \rightarrow \{AName, Geb, Adr, AbtNr\}$
- F2: $\{AbtNr\} \rightarrow \{Abt, ASV\}$
- Attributhülle $\alpha = \{SVNr\}$, mit $\alpha^+ = \alpha = \{SVNr\}$ initial
  - Betrachte F2, F1
    - Betrachte F2 mit $\beta = \{AbtNr\}$: $\beta \not\subseteq \alpha^+$ (keine Änderung)
    - Betrachte F1 mit $\beta = \{SVNr\}$: $\beta \subseteq \alpha^+$, damit $\alpha^+ = \alpha^+ \cup \{AName, Geb, Adr, AbtNr\}$
  - Änderung in α^+; also nochmal: Betrachte F2, F1
    - Betrachte F2 mit $\beta = \{AbtNr\}$: $\beta \subseteq \alpha^+$, damit $\alpha^+ = \alpha^+ \cup \{Abt, ASV\}$
    - Betrachte F1 mit $\beta = \{SVNr\}$: $\beta \subseteq \alpha^+$, aber keine Änderung in α^+
  - Änderung in α^+, also nochmal: Betrachte F2, F1
    - Keine Änderung mehr in α^+
  - Ausgabe: $\alpha^+ = \{SVNr, AName, Geb, Adr, AbtNr, Abt, ASV\}$

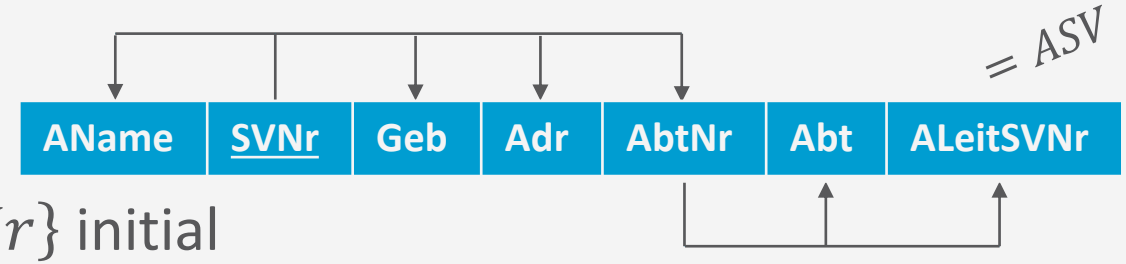

AttrHülle(F, α)
  $\alpha^+ \leftarrow \alpha$
  while α^+ geändert **do**
    for each $\beta \rightarrow \gamma \in F$ **do**
      if $\beta \subseteq \alpha^+$ **then**
        $\alpha^+ \leftarrow \alpha^+ \cup \gamma$
  return α^+

Attributhülle

- Attributhülle α^+ für eine Menge von Attributen α
  - Alle Attribute, die von α funktional abhängen
- Nutzen
  - Berechnung der transitiven Hülle F^+:
    - Für alle $\gamma \subseteq R$ und alle $S \subseteq \gamma^+$ enthält F^+ die FD $\gamma \rightarrow S$
  - Bestimmung von Superschlüsseln:
    - α Superschlüssel, wenn α^+ alle Attribute von R enthält
  - Überprüfung (voll) funktionaler Abhängigkeiten:
    - $\alpha \rightarrow \beta$ gilt, wenn $\beta \subseteq \alpha^+$

```
AttrHülle(F, α)
    α⁺ ← α
    while α⁺ geändert do
        for each β → γ ∈ F do
            if β ⊆ α⁺ then
                α⁺ ← α⁺ ∪ γ
    return α⁺
```

Redundanz in FDs & Kanonische Überdeckung

- Menge von FDs F kann redundante FDs enthalten oder FDs mit überflüssigen Attributen
  - Macht Überprüfung von Konsistenzen bei Änderungen im DB-Zustand aufwendiger als nötig
- Gesucht: Minimale Menge an FDs, die ausreichend sind, um F^+ zu beschreiben

→ Kanonische Überdeckung F_C, welche folgende drei Kriterien erfüllt

1. $F_C \equiv F$, d.h. $F_C^+ = F^+$
2. In F_C existieren keine FDs $\alpha \rightarrow \beta$, die überflüssige Attribute in α oder β enthalten
   - Kein überflüssiges Attribut in α: $\forall A \in \alpha : (F_C - \{\alpha \rightarrow \beta\}) \cup \{(\alpha - \{A\}) \rightarrow \beta\} \not\equiv F_C$
     - Test: Wenn $\beta \subseteq (\alpha - \{A\})^+$ bzgl. F_C, dann A überflüssig (kann aus α entfernt werden)
   - Kein überflüssiges Attribut in β: $\forall B \in \beta : (F_C - \{\alpha \rightarrow \beta\}) \cup \{\alpha \rightarrow (\beta - \{B\})\} \not\equiv F_C$
     - Test: Wenn $B \in \alpha^+$ bzgl. F_C ohne B in $\alpha \rightarrow \beta$, dann B überflüssig (kann aus β entfernt werden)
3. Jede linke Seite einer FD in F_C ist einzigartig
   - Additive Regel sukzessive anwenden: Wenn FDs $\alpha \rightarrow \beta, \alpha \rightarrow \gamma$, ersetze durch $\alpha \rightarrow \beta\gamma$

Kanonische Überdeckung: Berechnung

- Eingabe: Menge von FDs F
- Ausgabe: Kanonische Überdeckung F_C (Menge von FDs, welche die drei Kriterien erfüllt)
- Initialisiere F_C mit F

1. Führe für jede FD $\alpha \rightarrow \beta \in F_C$ die Linksreduktion durch:
   - Überprüfe für alle $A \in \alpha$:
     - Wenn $\beta \subseteq (\alpha - \{A\})^+$ bzgl. F_C, ersetze $\alpha \rightarrow \beta$ mit $(\alpha - \{A\}) \rightarrow \beta$ in F_C
2. Führe für jede FD $\alpha \rightarrow \beta \in F_C$ die Rechtsreduktion durch:
   - Überprüfe für alle $B \in \beta$:
     - Wenn $B \in \alpha^+$ bzgl. $(F_C - \{\alpha \rightarrow \beta\}) \cup \{\alpha \rightarrow (\beta - \{B\})\}$, ersetze $\alpha \rightarrow \beta$ mit $\alpha \rightarrow (\beta - \{B\})$ in F_C
3. Entferne die FDs der Form $\alpha \rightarrow \emptyset$ aus F_C
4. Ersetze alle FDs der Form $\alpha \rightarrow \beta_1, \ldots, \alpha \rightarrow \beta_n$ durch $\alpha \rightarrow (\beta_1 \cup \cdots \cup \beta_n)$ in F_C

Kanonische Überdeckung: Pseudocode

- Eingabe:
  Menge von FDs F
- Ausgabe:
  Kanonische Überdeckung F_C
- Initialisiere F_C mit F

1. Linksreduktion
2. Rechtsreduktion
3. FDs mit leerem β entfernen
4. FDs mit gleichem α zusammenfassen

KANON(F)
  $F_C \leftarrow F$
  for each $\alpha \rightarrow \beta \in F_C$ **do**
    for each $A \in \alpha$ **do**
      if $\beta \subseteq$ ATTRHÜLLE$(F_C, \alpha - \{A\})$ **then**
        $F_C \leftarrow (F_C - \{\alpha \rightarrow \beta\}) \cup \{(\alpha - \{A\}) \rightarrow \beta\}$
  for each $\alpha \rightarrow \beta \in F_C$ **do**
    for each $B \in \beta$ **do**
      if $B \in$ ATTRHÜLLE$\big((F_C - \{\alpha \rightarrow \beta\}) \cup \{\alpha \rightarrow (\beta - \{B\})\}, \alpha\big)$ **then**
        $F_C \leftarrow (F_C - \{\alpha \rightarrow \beta\}) \cup \{\alpha \rightarrow (\beta - \{B\})\}$
  for each $\alpha \rightarrow \beta \in F_C$ **do**
    if $\beta = \emptyset$ **then**
      $F_C \leftarrow F_C - \{\alpha \rightarrow \beta\}$
  while $\exists \alpha \rightarrow \beta_1, \ldots, \alpha \rightarrow \beta_n$ **do**
    $F_C \leftarrow (F_C - \{\alpha \rightarrow \beta_1, \ldots, \alpha \rightarrow \beta_n\}) \cup \{\alpha \rightarrow (\beta_1 \cup \cdots \cup \beta_n)\}$
  return F_C

Kanonische Überdeckung

- $F = \{S \to NG, G \to K, SN \to RG\} = F_C$

1. Linksreduktion: $SN \to RG$ in F_C testen
   - S überflüssig, d.h., $\{R, G\} \subseteq \{N\}^+ = \{N\}$?
     - Nein, daher keine Änderung in F_C
   - N überflüssig, d.h., $\{R, G\} \subseteq \{S\}^+ = \{S\} \cup \{N, G, K, R\}$?
     - Ja, daher $F_C \leftarrow (F_C - \{SN \to RG\}) \cup \{S \to RG\} = \{S \to NG, G \to K, S \to RG\}$

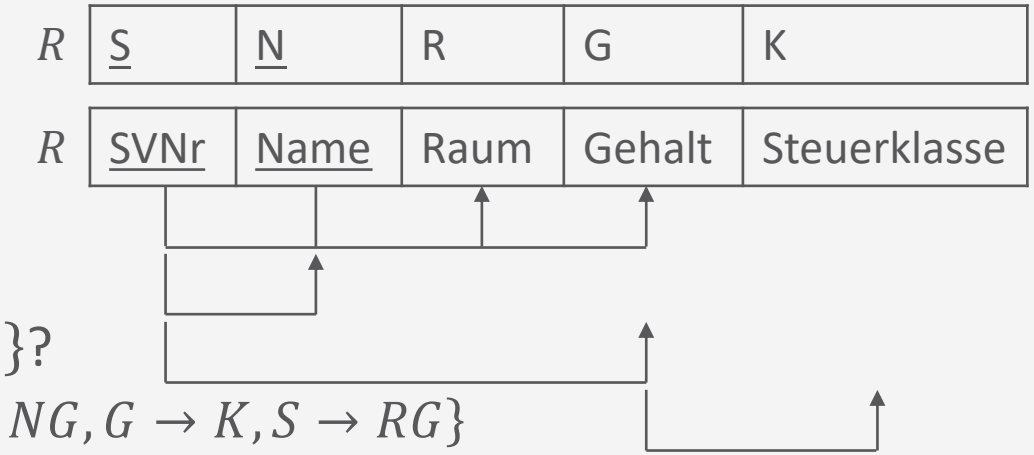

2. Rechtsreduktion: $S \to NG, S \to RG$ in F_C mit reduzierter FD testen
   - $S \to NG$: N überflüssig in $\{S \to G, G \to K, S \to RG\}$, d.h., $\{N\} \subseteq \{S\}^+ = \{S\} \cup \{G, K, R\}$?
     - Nein, daher keine Änderung in F_C
   - $S \to NG$: G überflüssig in $\{S \to N, G \to K, S \to RG\}$, d.h., $\{G\} \subseteq \{S\}^+ = \{S\} \cup \{N, R, G\} \cup \{K\}$?
     - Ja, daher $F_C \leftarrow (F_C - \{S \to NG\}) \cup \{S \to N\} = \{S \to N, G \to K, S \to RG\}$
   - $S \to RG$: beide nicht überflüssig

Kanonische Überdeckung

- $F = \{S \rightarrow NG, G \rightarrow K, SN \rightarrow RG\} = F_C$
- $F_C = \{S \rightarrow N, G \rightarrow K, S \rightarrow RG\}$ nach Schritt 1 + 2

3. FDs mit leerem β entfernen
   - Keine Änderung
4. FDs mit gleichem α zusammenfassen
   - $F_C \leftarrow (F_C - \{S \rightarrow N, S \rightarrow RG\}) \cup \{S \rightarrow NRG\} = \{S \rightarrow NRG, G \rightarrow K\}$

- Ergebnis: $F_C = \{S \rightarrow NRG, G \rightarrow K\}$

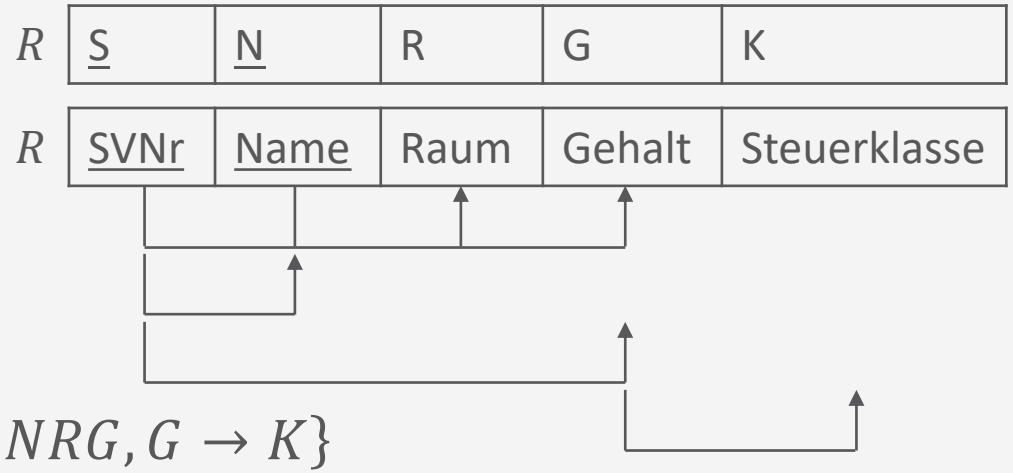

Ist F_C eindeutig?

Kanonische Überdeckung: Abstraktes Beispiel

- Relation über A, B, C
  - $F = \{A \to BC, B \to CA, C \to A\} = F_C$
- Schritt mit Effekt: Rechtsreduktion
  - $A \to BC$ zuerst betrachten
  - $A \to BC$: $B \in \{A\}^+ = \{A\} \cup \{C\}$?
    - Nein, keine Änderung
  - $A \to BC$: $C \in \{A\}^+ = \{A\} \cup \{C\}$?
    - Ja, daher $F_C = \{A \to B, B \to CA, C \to A\}$
  - $B \to CA$: $C \in \{B\}^+ = \{B\} \cup \{A\}$?
    - Nein, keine Änderung
  - $B \to CA$: $A \in \{B\}^+ = \{B\} \cup \{A\}$?
    - Ja, daher $F_C = \{A \to B, B \to C, C \to A\}$

- Relation über A, B, C
  - $F = \{A \to BC, B \to CA, C \to A\} = F_C$
- Schritt mit Effekt: Rechtsreduktion
  - $B \to CA$ zuerst betrachten
  - $B \to CA$: $C \in \{B\}^+ = \{B\} \cup \{A, C\}$?
    - Ja, daher $F_C = \{A \to BC, B \to A, C \to A\}$
  - $A \to BC$: $B \in \{A\}^+ = \{A\} \cup \{C\}$?
    - Nein, keine Änderung
  - $A \to BC$: $C \in \{A\}^+ = \{A\} \cup \{B\}$?
    - Nein, keine Änderung
  - Ergebnis: $F_C = \{A \to BC, B \to A, C \to A\}$

Kanonische Überdeckung nicht immer eindeutig

Zwischenzusammenfassung

- Probleme bei schlecht gebauten Relationen:
  - Einfüge-Anomalien, Update-Anomalien, Lösch-Anomalien
- Bewertung der Qualität über Konsistenzbedingungen durch FDs und Redundanz
- FDs
  - Erlauben Schlüssel zu bestimmen: Relation dann voll funktional abhängig
  - Transitive Hülle: Herleitung über Inferenzregeln (RATZAP)
  - Attributhülle: Menge von Attributen, die funktional abhängig sind von gegebenen Attributen
    - Erlaubt Berechnung von Superschlüsseln und transitiver Hülle, Test von funktionalen Abhängigkeiten
  - Kanonische Überdeckung zur Minimierung der Menge der FDs durch Entfernung von überflüssigen Attributen und FDs
    - Vorgehen: Rechtsreduktion, Linksreduktion, leere FDs löschen, gleiche α Regeln zusammenfassen
    - Nutzt auch die Attributhülle in ihren Berechnungen

Überblick: 4. Datenbankentwurf

A. Funktionale Abhängigkeiten

- Definition, Schlüssel, Ableitungen
- Attributhülle, kanonische Überdeckung

B. Normalformen

- Zerlegung von Relationen
- (Exkurs: NF^2), 1NF, 2NF, 3NF, BCNF, 4NF, 5NF
- Synthesealgorithmus, Zerlegungsalgorithmus

C. Datenqualität

- Datenqualitätsprobleme, Dimensionen der Datenqualität

Erinnerung: Ziele der relationalen Entwurfstheorie

- Bewertung der Qualität eines Relationenschemas
  - Redundanz
    - Viel Redundanz erhöht Gefahr für Anomalien, vor allem bei Updates
  - Einhaltung von Konsistenzbedingungen
    - Funktionale Abhängigkeiten, anhand derer Konsistenz geprüft werden kann
- Normalformen als Gütekriterium
- Gegebenenfalls Verbesserung eines Relationenschemas durch
  - Synthesealgorithmus
  - Zerlegungsalgorithmus

- Meist gute Qualität bei aus validen ER-Diagrammen erstellten DB-Schemata

Normalisierung von Datenbank-Schemata & Normalformen (NF)

- Normalisierung bietet:
  - Normalformbedingungen, um NF zu testen
  - Vorgehen, um NF zu erreichen
    - Grundsätzliches Vorgehen:
      - Prüfung eines Relationenschemas auf eine Normalform
      - Wenn nicht erfüllt: Zerlegung in neue Relationenschemata, bis gewünschte Normalform erreicht ist
    - Je höher die NF, desto weniger Redundanz

Zerlegung von Schemata

- Zur Herstellung einer NF:
  Zerlegung eines Schemas R in Menge von Schemata $D = \{R_1, \dots, R_n\}$
  - Attributerhaltung der Zerlegung D:
    - Jedes Attribut aus R erscheint in mindestens einem R_i
    - Vereinigung der Attributmengen aller R_i entspricht damit der Attributmenge von R
- Korrektheitskriterien (beide sollen möglichst gelten)
  1. Verlustlosigkeit bzw. Eigenschaft des nicht-additiven JOINs
     - Die im ursprünglichen Relationenzustand $r(R)$ enthaltenen Informationen müssen aus den Zuständen der neuen Schemata D rekonstruierbar sein → keine unechten Tupel entstehen lassen
  2. Abhängigkeitserhaltung
     - Die für R geltenden Abhängigkeiten müssen auf die Schemata in D übertragbar sein

  ❖ Zusätzlich soll gelten, dass möglichst wenig Redundanz in den Daten herrscht

Beispiel

- Zerlegung, die nicht die Eigenschaft des nicht-additiven JOINs erfüllt

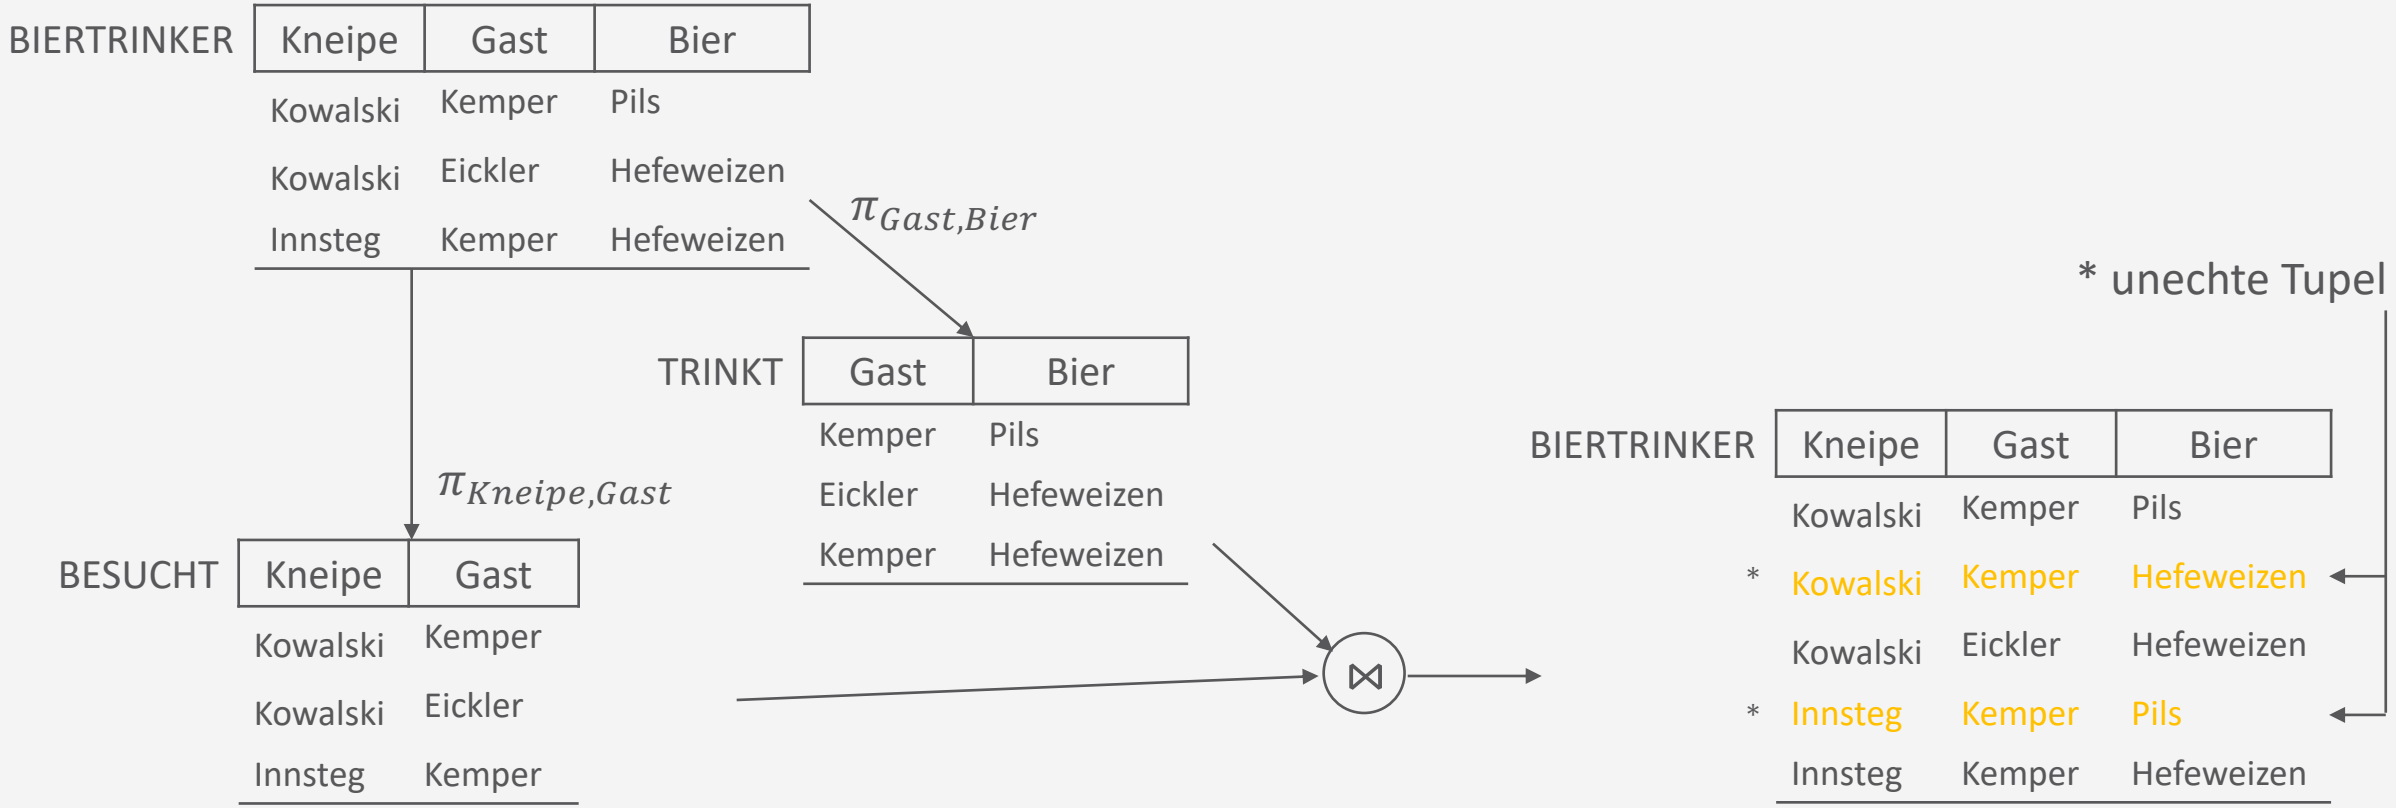

Verlustlosigkeit bzw. nicht-additiver JOIN

- Zerlegung $D = \{R_1, \dots, R_m\}$ von R ist verlustlos in Bezug auf die Abhängigkeitsmenge F in R, wenn für jede Relation $r(R)$, die F erfüllt, gilt

$$\bowtie \left(\pi_{R_1}(r), \dots, \pi_{R_m}(r)\right) = r$$

  - $\bowtie$ bezeichnet hier den NATURAL JOIN

- *Hinreichende Bedingung* für $D = \{R_1, R_2\}$ von R
  - Wenn $(R_1 \cap R_2) \rightarrow R_1 \in F^+$ oder $(R_1 \cap R_2) \rightarrow R_2 \in F^+$, dann ist D verlustlos

- D.h. JOINs über die zerlegten Relationen erzeugen keine „unechten“ Tupel
  - Informationsgehalt von R und D bleibt gleich

Nicht-additiver JOIN-Test

- Input: Relationenschema R über Attribute $A_1, \ldots, A_n$, Zerlegung $D = \{R_1, R_2, \ldots, R_m\}$ von R, Menge von FDs F
  1. Erzeuge eine Matrix S mit m Zeilen und n Spalten und fülle S mit 0‘n
  2. Für jede Zeile i (Relation R_i), jede Spalte j (Attribut A_j):
     - Wenn A_j in R_i vorkommt: Setze $S(i,j) \coloneqq 1$
  3. Wiederhole, bis keine Änderung mehr in S vorkommt:
     - Für jede FD $X \rightarrow Y$ in F
       - $I \leftarrow$ Sammle die Zeilen, die für alle Attribute in X eine 1 stehen haben
       - Für jedes Attribut $A_j \in Y$
         Falls es ein $i \in I$ gibt, so dass $S(i,j) = 1$: Setze $S(i',j) \coloneqq 1$ für alle $i' \in I, i' \neq i$
         Sonst: Setze $S(i',j) \coloneqq 0$ für alle $i' \in I$
  4. Besteht eine Zeile vollständig aus 1‘n, dann weist die Zerlegung die Eigenschaft des nicht-additiven JOINs auf, im anderen Fall hat die Zerlegung diese Eigenschaft nicht

Nicht-additiver JOIN-Test: Beispiel 1

- Gegeben $R = ANGEST\_PROJ = \{SVNr, AName, PNr, PName, PStandort, Std\}$
  - $F = \{\{SVNr\} \rightarrow \{AName\}, \{PNr\} \rightarrow \{PName, PStandort\}, \{SVNr, PNr\} \rightarrow \{Std\}\}$
- Zerlegung $D = \{R_1, R_2\}$
  - $R_1 = ANGEST\_ORTE = \{AName, PStandort\}$
  - $R_2 = ANGEST\_PROJ1 = \{SVNr, PNr, Std, PName, PStandort\}$

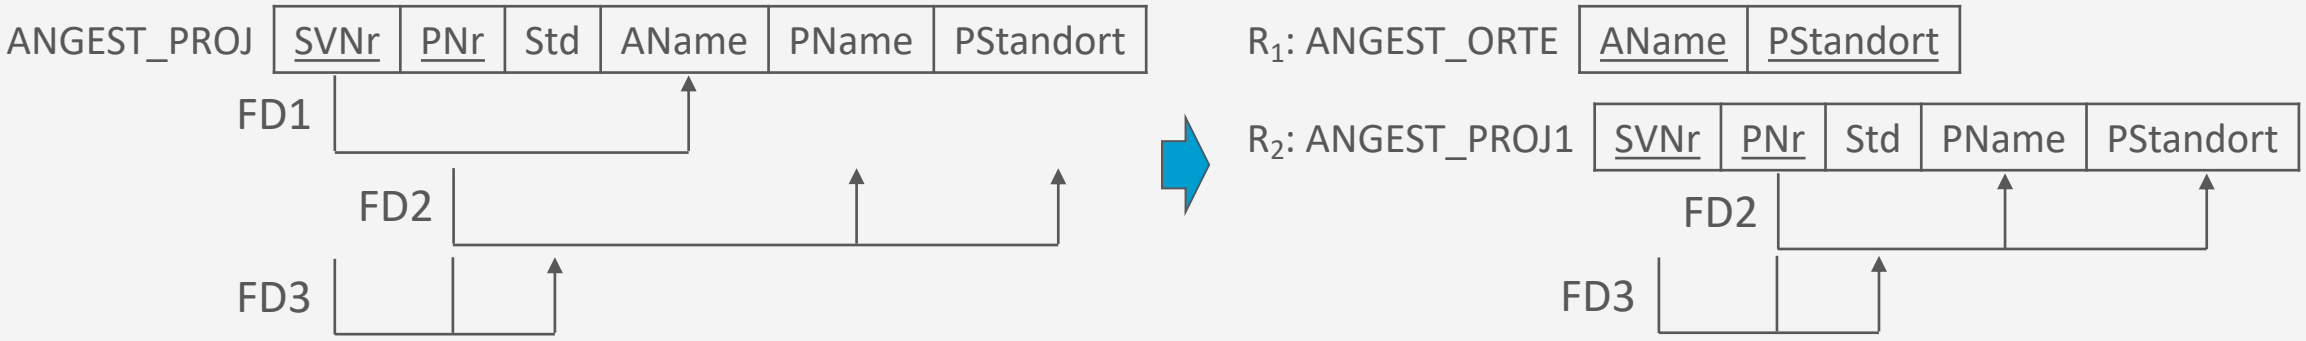

Nicht-additiver JOIN-Test: Beispiel 1

- Matrix:

	SVNr	AName	PNr	PName	PStandort	Std
R_1	0	1	0	0	1	0
R_2	1	0	1	1	1	1

- Keine Änderung über die Schleife
- Keine Zeile nur mit 1‘n, d.h. keine Zerlegung mit gewünschter Eigenschaft → Additiver JOIN!

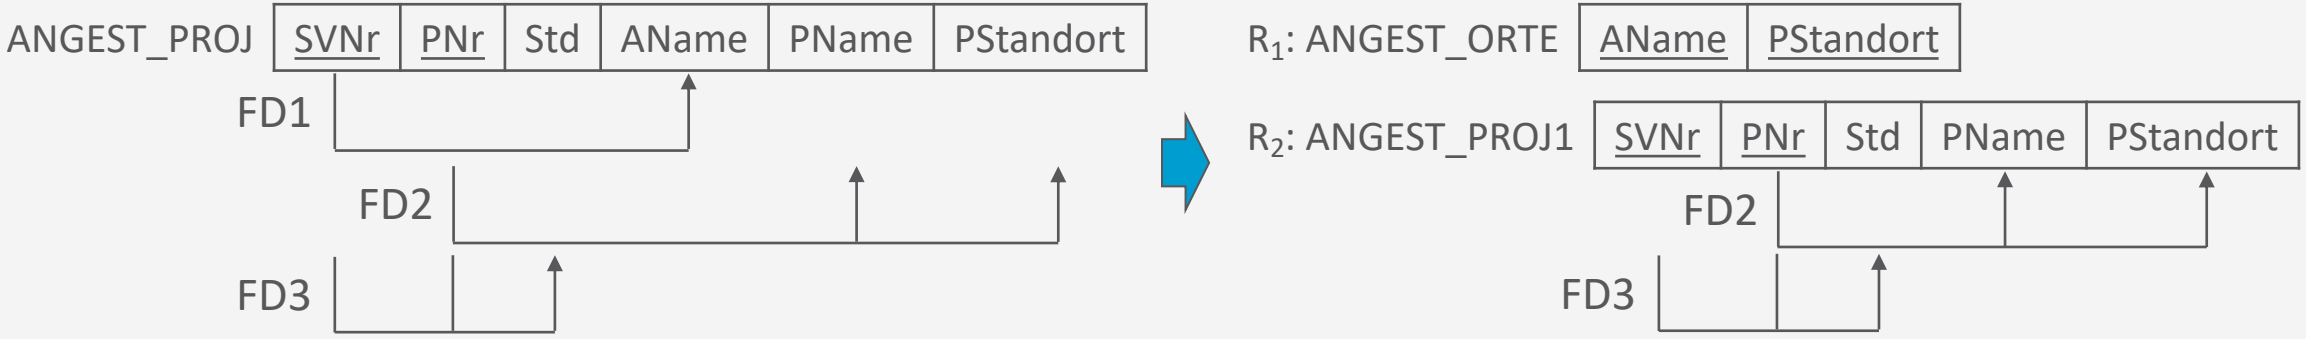

Nicht-additiver JOIN-Test: Beispiel 2

- Alternative Zerlegung von $ANGEST\_PROJ$
  - Gegeben $R = ANGEST\_PROJ = \{SVNr, AName, PNr, PName, PStandort, Std\}$
    - $F = \{\{SVNr\} \rightarrow \{AName\}, \{PNr\} \rightarrow \{PName, PStandort\}, \{SVNr, PNr\} \rightarrow \{Std\}\}$
  - Zerlegung $D = \{R_1, R_2, R_3\}$
    - $R_1 = ANGEST = \{SVNr, AName\}$
    - $R_2 = PROJEKT = \{PNr, PName, PStandort\}$
    - $R_3 = ARBEITET\_AN = \{SVNr, PNr, Std\}$

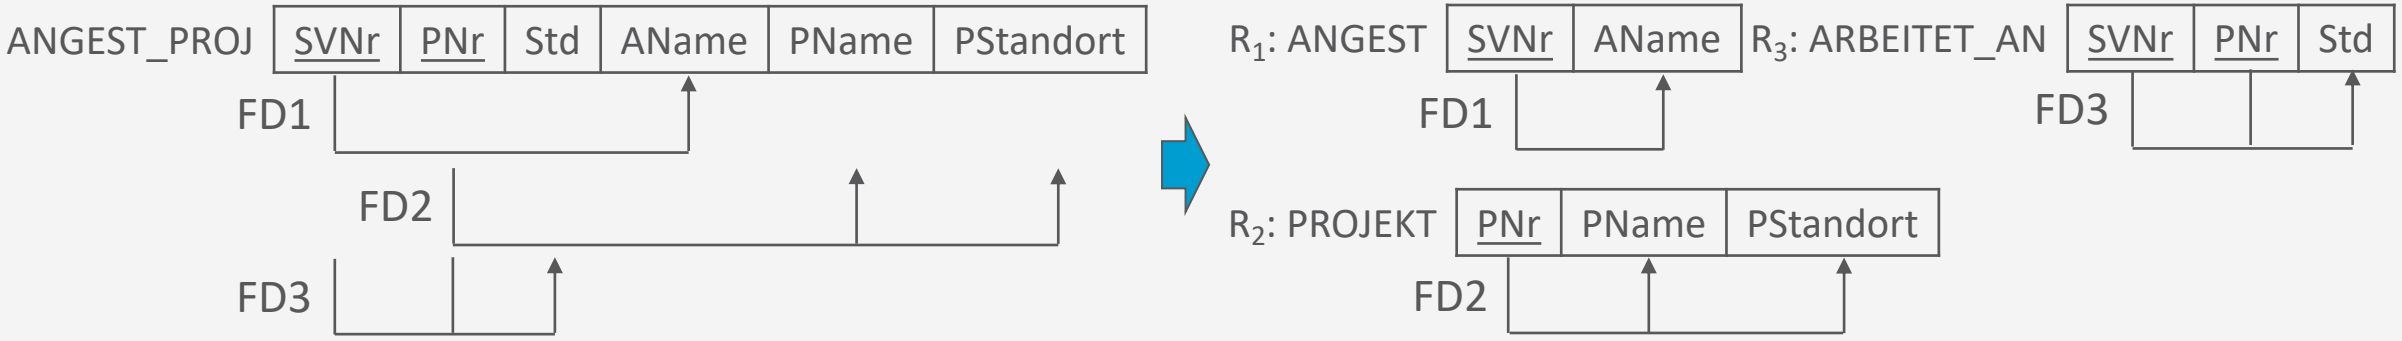

Nicht-additiver JOIN – Test: Beispiel 2

- Matrix
  - Nach Schritt 3:

	SVNr	AName	PNr	PName	PStandort	Std
R_1	1	1	0	0	0	0
R_2	0	0	1	1	1	0
R_3	1	0	1	0	0	1

  - Nach FD1 und FD2 in Schritt 4

	SVNr	AName	PNr	PName	PStandort	Std
R_1	1	1	0	0	0	0
R_2	0	0	1	1	1	0
R_3	1	1	1	1	1	1

Zeile R_3 nur mit 1‘n → nicht-additive JOIN-Zerlegung

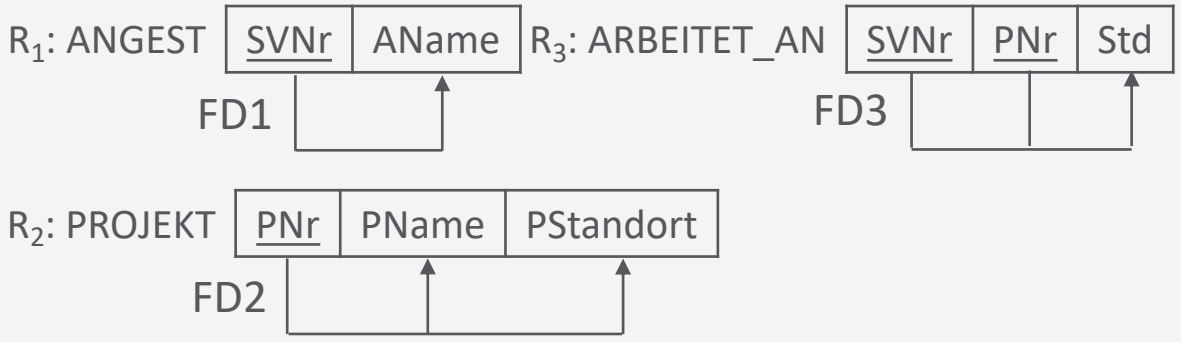

Nebenbemerkung: Unechte Tupel

- Auch aus Equijoins über Nicht-Schlüssel-Attribute können unechte (*spurious*) Tupel entstehen
  - Abhilfe:
    - Vermeidung gleichlautender Attribute, die keine Schlüssel sind
    - Wenn dies unvermeidbar ist: kein Join darüber bzw. Join nur über Schlüsselattribute
- Beispiel:
  - $ANGEST\_ORTE \bowtie ANGEST\_PROJ1$ (Natural Join)

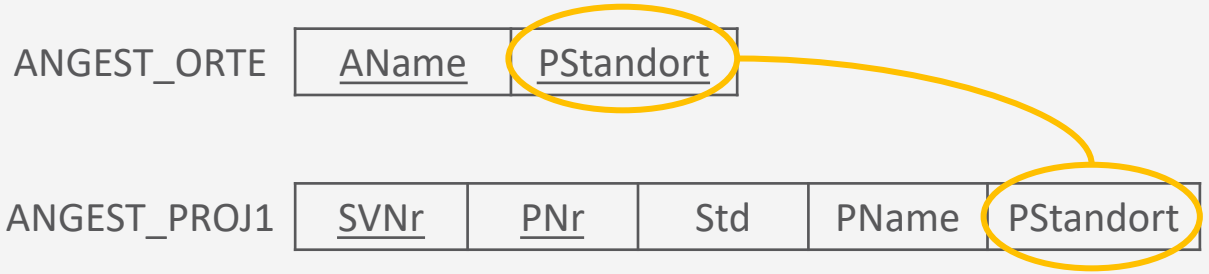

Beispiel

ANGEST_ORTE

AName	PStandort
Smith, John B.	Bellaire
Smith, John B.	Sugarland
Narayan, Ramesh K.	Houston
English, Joyce A.	Bellaire
English, Joyce A.	Sugarland
Wong, Franklin T.	Sugarland
Wong, Franklin T.	Houston
	Stafford
	Stafford
	Stafford
	Stafford
	Houston
	Houston

ANGEST_PROJ1

SVNr	PNr	Std	PName	PStandort
123456789	1	32.5	Product X	Bellaire
123456789	2	7.5	Product Y	Sugarland
666884444	3	40.0	Product Z	Houston
453453453	1	20.0	Product X	Bellaire
453453453	2	20.0	Product Y	Sugarland

AName	SVNr
Smith, John B.	123456789
Wong, Franklin T.	333445555
Wallace, Jennifer S.	987654321
Narayan, Ramesh K.	666884444
English, Joyce A.	453453453
Borg, James E.	888665555

* unechte Tupel

	SVNr	PNr	Std	PName	PStandort	AName
	123456789	1	32.5	Product X	Bellaire	Smith, John B.
*	123456789	1	32.5	Product X	Bellaire	English, Joyce A.
	123456789	2	7.5	Product Y	Sugarland	Smith, John B.
*	123456789	2	7.5	Product Y	Sugarland	English, Joyce A.
*	123456789	2	7.5	Product Y	Sugarland	Wong, Franklin T.
	666884444	3	40.0	Product Z	Houston	Narayan, Ramesh K.
*	666884444	3	40.0	Product Z	Houston	Wong, Franklin T.
*	666884444	3	40.0	Product Z	Houston	Wallace, Jennifer S.
*	666884444	3	40.0	Product Z	Houston	Borg, James E.
*	453453453	1	20.0	Product X	Bellaire	Smith, John B.
	453453453	1	20.0	Product X	Bellaire	English, Joyce A.
	⋮					

Abhängigkeitswahrung

- Jede in F spezifizierte FD $X \rightarrow Y$
  - Soll direkt in einem der R_i aus der Zerlegung D erscheinen oder
  - (Indirekt) aus den Abhängigkeiten, die in den R_i gelten, abgeleitet werden können
  - Warum ist das wichtig?
    - Wenn Abhängigkeiten verloren gehen, dann ist das Einfügen inkonsistenter Tupel möglich
- Formale Betrachtung
  - Gegeben sei eine Menge von FDs F in R
  - Dann ist die Projektion $\pi_{R_i}(F)$ von F auf R_i (für alle R_i aus D) die Menge von Abhängigkeiten $X \rightarrow Y$ in F^+, für die alle Attribute $X \cup Y$ in R_i vorkommen
  - Die Zerlegung $D = \{R_1, \ldots, R_m\}$ von R heißt in Bezug auf F abhängigkeitswahrend, wenn die Vereinigung der Projektionen von F auf jedes R_i in D mit F äquivalent ist, i.e.,

$$\left(\pi_{R_1}(F) \cup \cdots \cup \pi_{R_m}(F)\right)^+ = F^+$$

Test auf Abhängigkeitserhaltung

- Überprüfung, ob FD $\alpha \rightarrow \beta$ aus einer Menge von FDs F in einer Zerlegung $D = \{R_1, \ldots, R_m\}$ einer Relation R erhalten bleibt

```
AbhErhaltend(D, α, β)
    res ← α
    while res geändert do
        for each R_i ∈ D do
            t ← (res ∩ R_i)^+ ∩ R_i
            res ← res ∪ t
    if β ⊆ res then
        return true
    else
        return false
```

Warum können wir diese ausschießen?

- Für eine eine Menge von FDs F:
  - Prüfe jede $\alpha \rightarrow \beta$ in F, *die sich nicht ausschließlich auf ein Teilschema R_i beziehen*, auf Abhängigkeitserhaltung

- Polynomieller Aufwand

Abhängigkeitswahrung: Beispiel 1

- Zerlegung, die nicht alle FDs erhält …
  - Bei der unten gezeigten Zerlegung von GeoInfo in die Relationenschemata GeoInfoX und GeoInfoY geht FD2 verloren
    - (Verzeichnis_ID# könnte z.B. für GPS-Koordinaten stehen)
    - (FD3 stimmt nur unter der Annahme, dass PLZ nicht länder- bzw. ortsübergreifend sind)

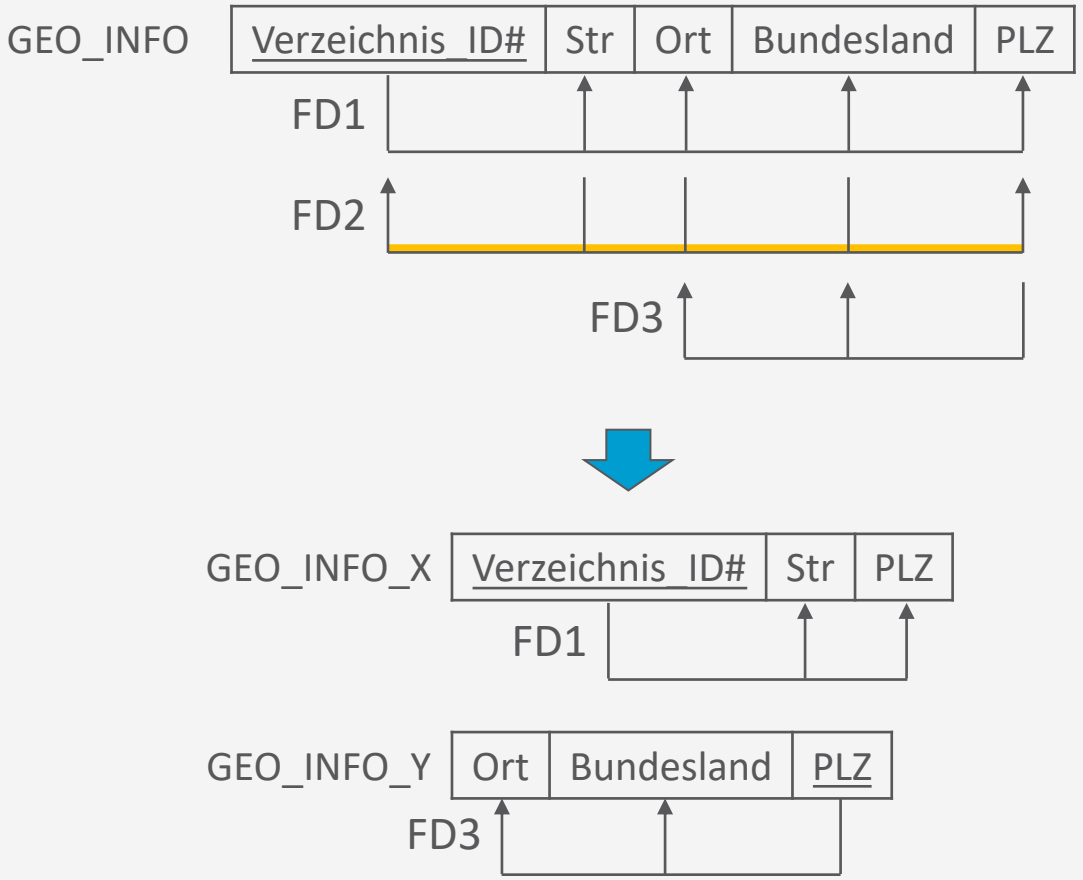

Abhängigkeitswahrung: Beispiel 2

- Gegeben ist die Relation $EXERCISE$ mit den FDs
  - FD1 : $\{Student, Course\} \rightarrow \{Tutor\}$
  - FD2 : $\{Tutor\} \rightarrow \{Course\}$
- Mögliche Zerlegungen
  - $(Student, Tutor)$ und $(Student, Course)$
  - $(Course, Tutor)$ und $(Student, Course)$
  - $(Course, Tutor)$ und $(Student, Tutor)$
  - FD1 geht bei allen möglichen Zerlegungen verloren, denn man kann sie auch nicht implizit aus FD2 herleiten

EXERCISE

Student	Course	Tutor
Narayan	Information Systems	Mark
Smith	Information Systems	Navathe
Smith	Operating Systems	Ammar
Smith	Formal Languages	Schulz
Wallace	Information Systems	Mark
Wallace	Operating Systems	Ahamad
Wong	Information Systems	Otte
Zelaya	Information Systems	Navathe

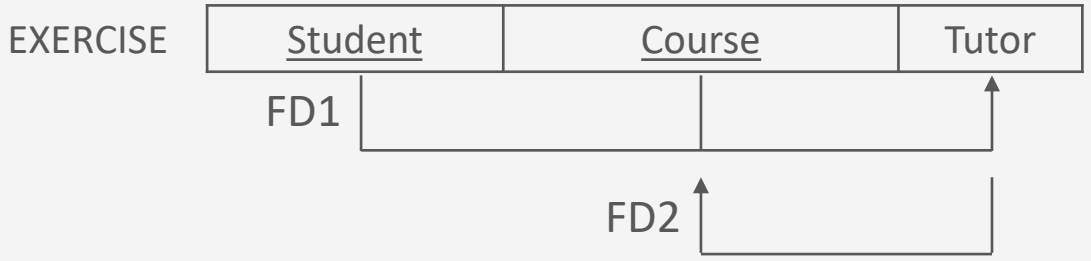

Normalformen

Zerlegungen von Relationen

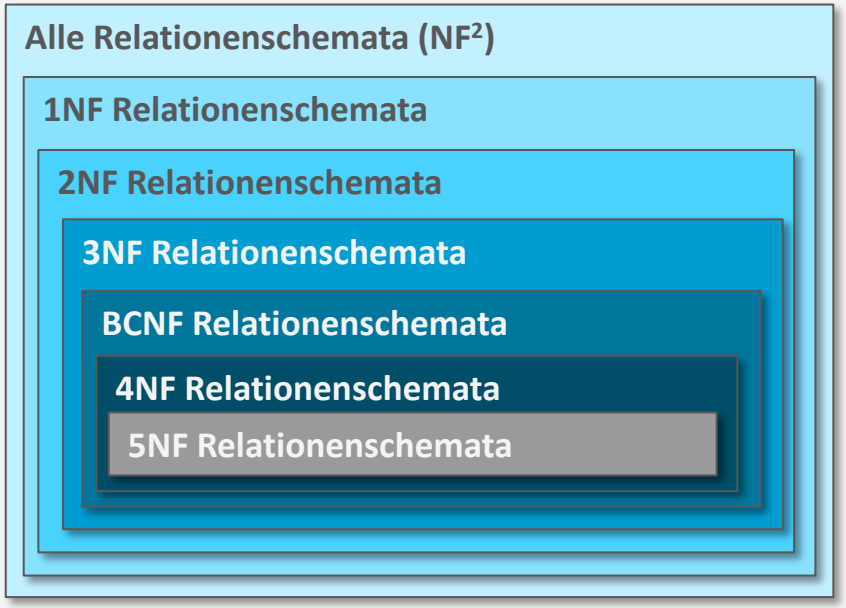

Historie

- Normalisierungsverfahren: 1972 von Codd vorgeschlagen
  - Unterzieht DB-Schemata einer Reihe von Tests, ob sie einer bestimmten NF genügen
  - Ursprünglich 1. – 3. Normalform (1NF, 2NF, 3NF)
  - Dann Verschärfung der 3. NF: Boyce Codd Normalform (BCNF)
  - Später: 4. und 5. Normalform
- NFs enthalten einander
  - Siehe Abbildung rechts

Abhängigkeitserhaltende Zerlegung (bis 3NF)

Verlustlose Zerlegung (bis 5NF)

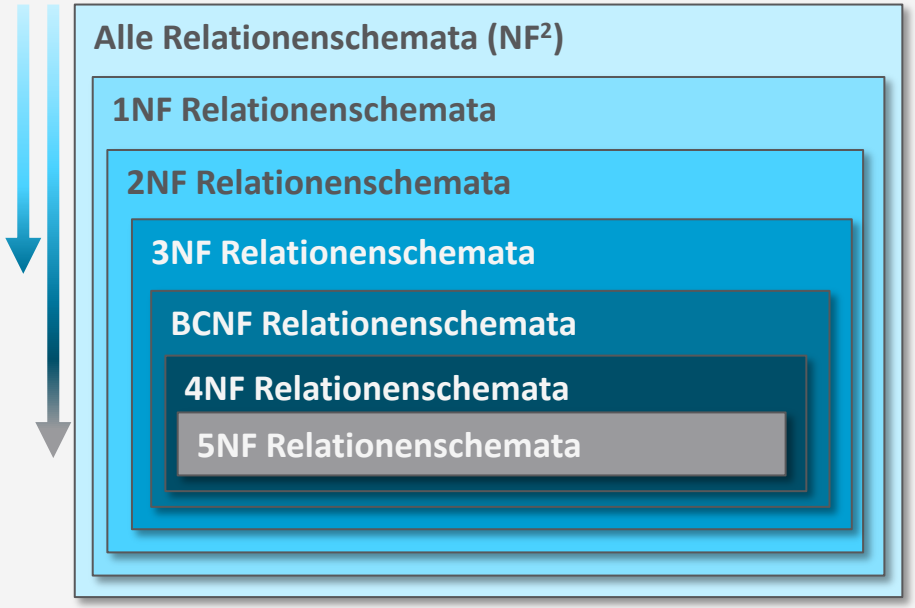

Nebenbemerkung: Non-first Normal Form (NF^2)

- Relationen mit
  - Nicht-atomaren Einträgen
    - Listen
    - Zusammengesetzte Einträge
  - Geschachtelten Relationen

ELTERN

Vater	Mutter	Kinder	
		KName	KAlter
Johann	Martha	Else	5
		Lucie	3
Johann	Maria	Theo	3
		Josef	1
Heinz	Martha	Cleo	9

ADR

Straße	PLZ+Ort
Baumstr	2500 Biel
Parkstr	3000 Bern
Wiesenstr	3018 Bern
Baumstr	3018 Bern

ABT

Abt	AbtNr	ALeitSVNr	AStandort
Research	5	333445555	{Bellaire, Sugarland, Houston}
Administration	4	987654321	{Stafford}
Headquarters	1	888665555	{Houston}

1. Normalform

- Relationenschema R ist in 1. Normalform (1NF), wenn
  - Domänen der Attribute von R nur atomare Werte enthalten
- Erzeugung:
  - Erstelle für jedes nicht-atomare Attribut oder für verschachtelte Schemata ein neues Relationenschema
    - Bei Übersetzung aus einem ER-Diagramm
      - *Zusammengesetzte* Attribute in seinen Einzelteilen als Attribute übernehmen
      - *Mehrwertige* Attribute in eigene Relation auslagern

ADR

Straße	PLZ	Ort
Baumstr	2500	Biel
Parkstr	3000	Bern
Wiesenstr	3018	Bern
Baumstr	3018	Bern

ADR

Straße	PLZ+Ort
Baumstr	2500 Biel
Parkstr	3000 Bern
Wiesenstr	3018 Bern
Baumstr	3018 Bern

ABT

Abt	AbtNr	ALeitSVNr	AStandort
Research	5	333445555	{Bellaire, Sugarland, Houston}
Administration	4	987654321	{Stafford}
Headquarters	1	888665555	{Houston}

ABT

Abt	AbtNr	ALeitSVNr
Research	5	333445555
Administration	4	987654321
Headquarters	1	888665555

ABTSTAN

AbtNr	AStandort
5	Bellaire
5	Sugarland
5	Houston
4	Stafford
1	Houston

1. Normalform

- Effekt:
  - Keine zusammengesetzten, mengenwertige oder geschachtelten Werte
- Praktischer Nutzen:
  - Erleichtert oder ermöglicht sogar erst Anfragen an die DB durch atomare Einträge
    - Beispiel: Alle Straßen im Ort „Bern“
      - Sonst nicht möglich, da nur Anfragen an alle Straßen in „3000 Bern“, „3018 Bern“ möglich oder mittels aufwendiger Substring-Suche
    - Beispiel: Alle Abteilungen am Standort „Bellaire“
      - Erleichtert, da sonst Suche in Liste für jede Abteilung nötig

ADR

Straße	PLZ	Ort
Baumstr	2500	Biel
Parkstr	3000	Bern
Wiesenstr	3018	Bern
Baumstr	3018	Bern

ADR

Straße	PLZ+Ort
Baumstr	2500 Biel
Parkstr	3000 Bern
Wiesenstr	3018 Bern
Baumstr	3018 Bern

ABT

Abt	AbtNr	ALeitSVNr	AStandort
Research	5	333445555	{Bellaire, Sugarland, Houston}
Administration	4	987654321	{Stafford}
Headquarters	1	888665555	{Houston}

ABT

Abt	AbtNr	ALeitSVNr
Research	5	333445555
Administration	4	987654321
Headquarters	1	888665555

ABTSTAN

AbtNr	AStandort
5	Bellaire
5	Sugarland
5	Houston
4	Stafford
1	Houston

2. Normalform

- Relationenschema R ist in 2. Normalform (2NF), wenn
  - R in 1NF ist und
  - Kein nicht-primes Attribut von nur einem Teil eines Schlüsselkandidaten abhängt
- Erzeugung:
  - Zerlege das Relationenschema und erstelle ein neues für jeden Teil-Schlüssel mit seinen abhängigen Attributen
  - Erhalte das (restliche) Relationenschema mit dem ursprünglichen Primärschlüssel und Attributen, die von diesem voll funktional abhängig sind

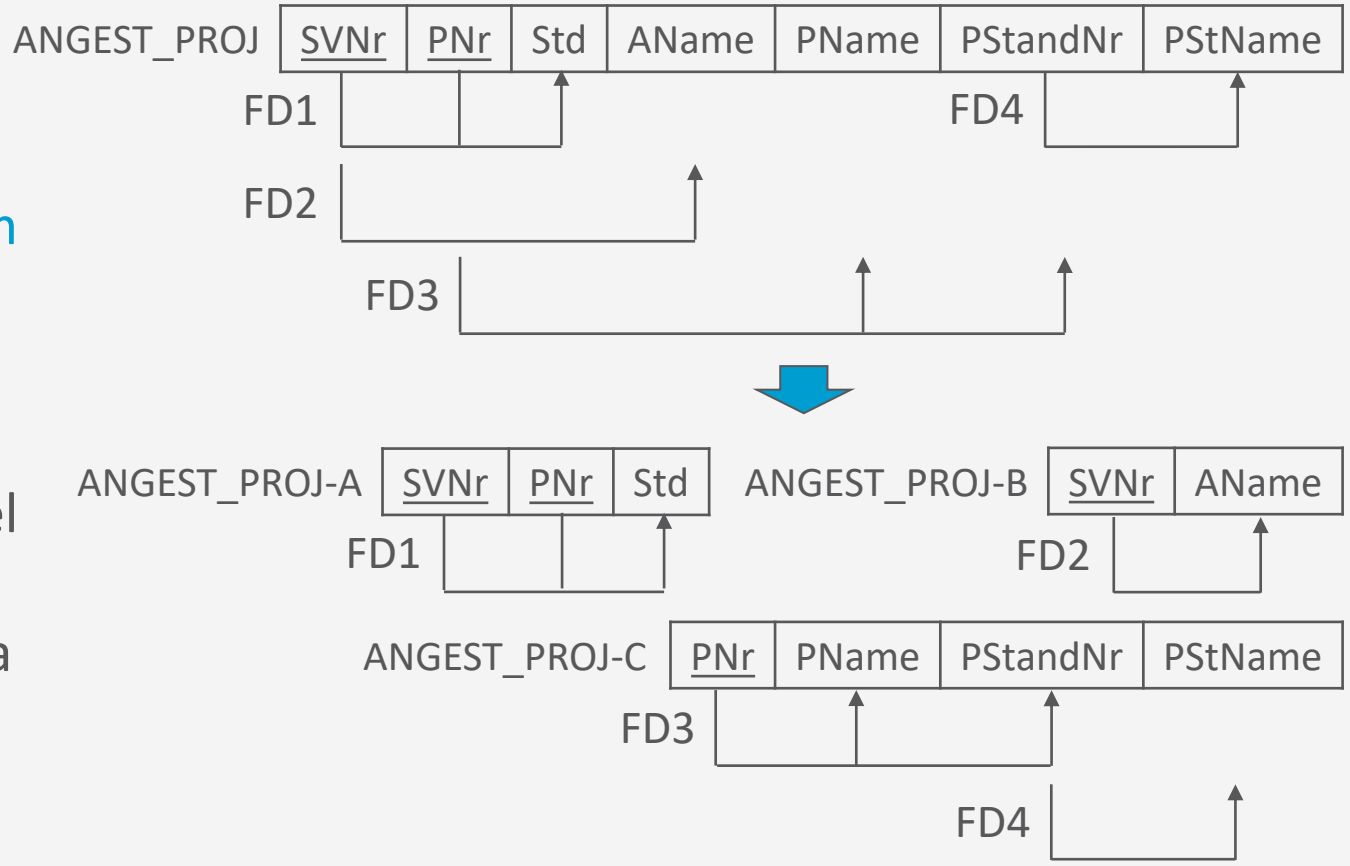

2. Normalform

- Effekt:
  - Alle nicht-primen Attribute sind voll funktional von allen Schlüsselkandidaten abhängig
    - Voll funktional: Von allen Schlüsselattributen (und nicht nur einer Teilmenge eines zusammengesetzten Kandidaten) funktional abhängig
    - Heißt auch, wenn nur ein primes Attribut, dann ist eine Relation in 1NF auch in 2NF
- 2NF bei Erzeugung aus ER-Diagramm in der Regel gegeben

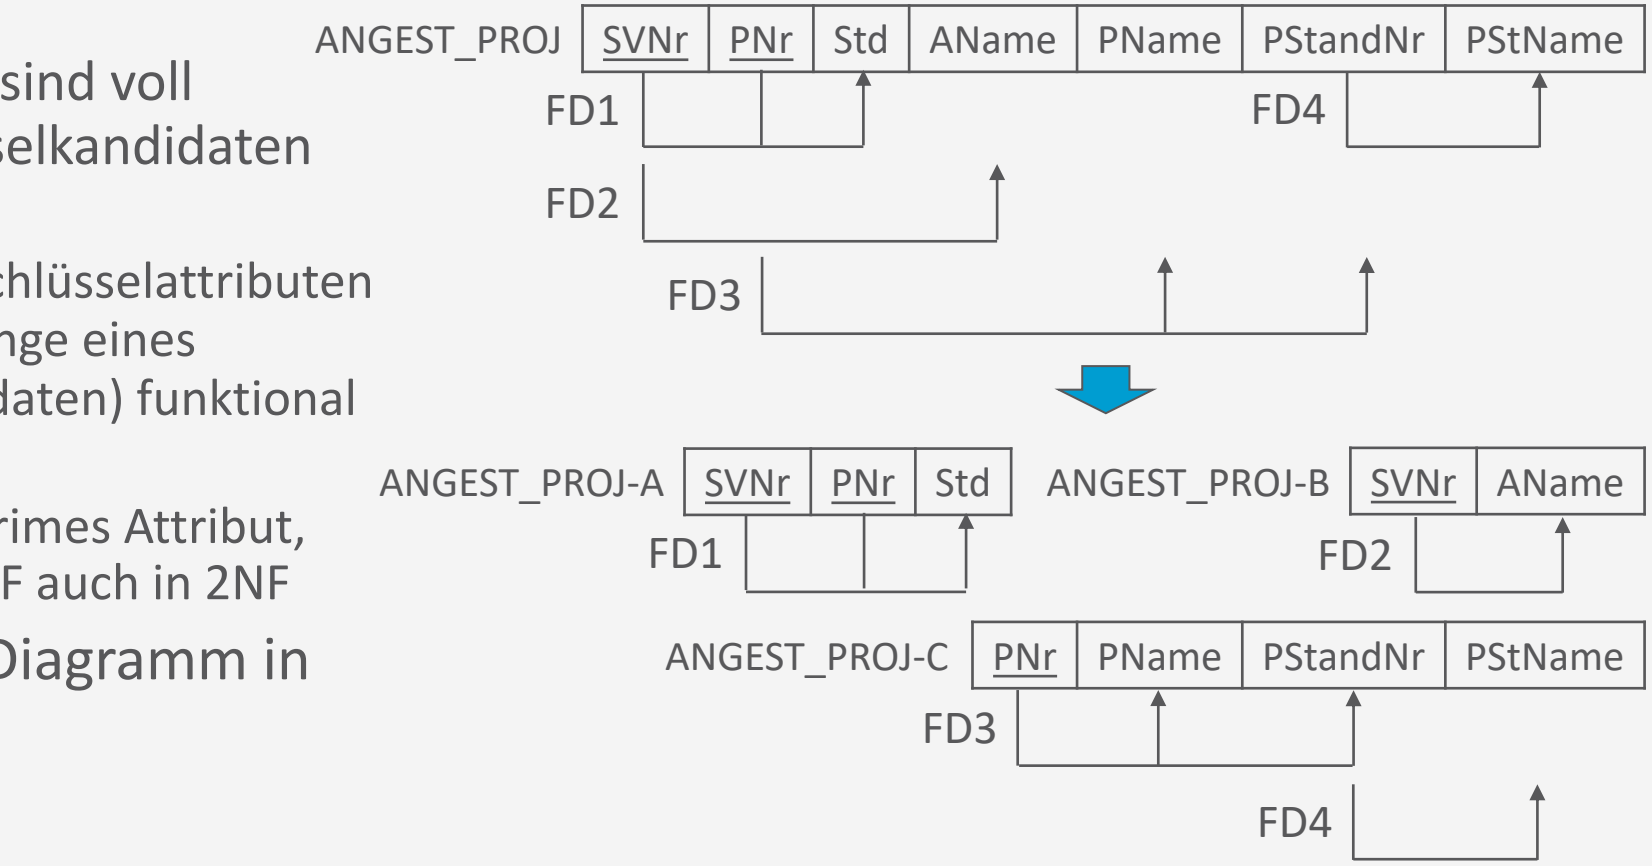

2. Normalform

- Praktischer Nutzen
  - Relationen enthalten logisch zusammengehörige Informationen (*Abgrenzung*)
  - *Reduktion redundanter Werte*
    - Anomalien bei Veränderungen vermeiden
    - Beispiel: $AName$ einmal pro $SVNr$
      - Gleiches gilt für Werte pro PNr
- Probleme:
  - Immer noch redundante Werte möglich, was zu Anomalien führen kann
    - Beispiel: Standortnamen werden jedes Mal für einen Standort wiederholt

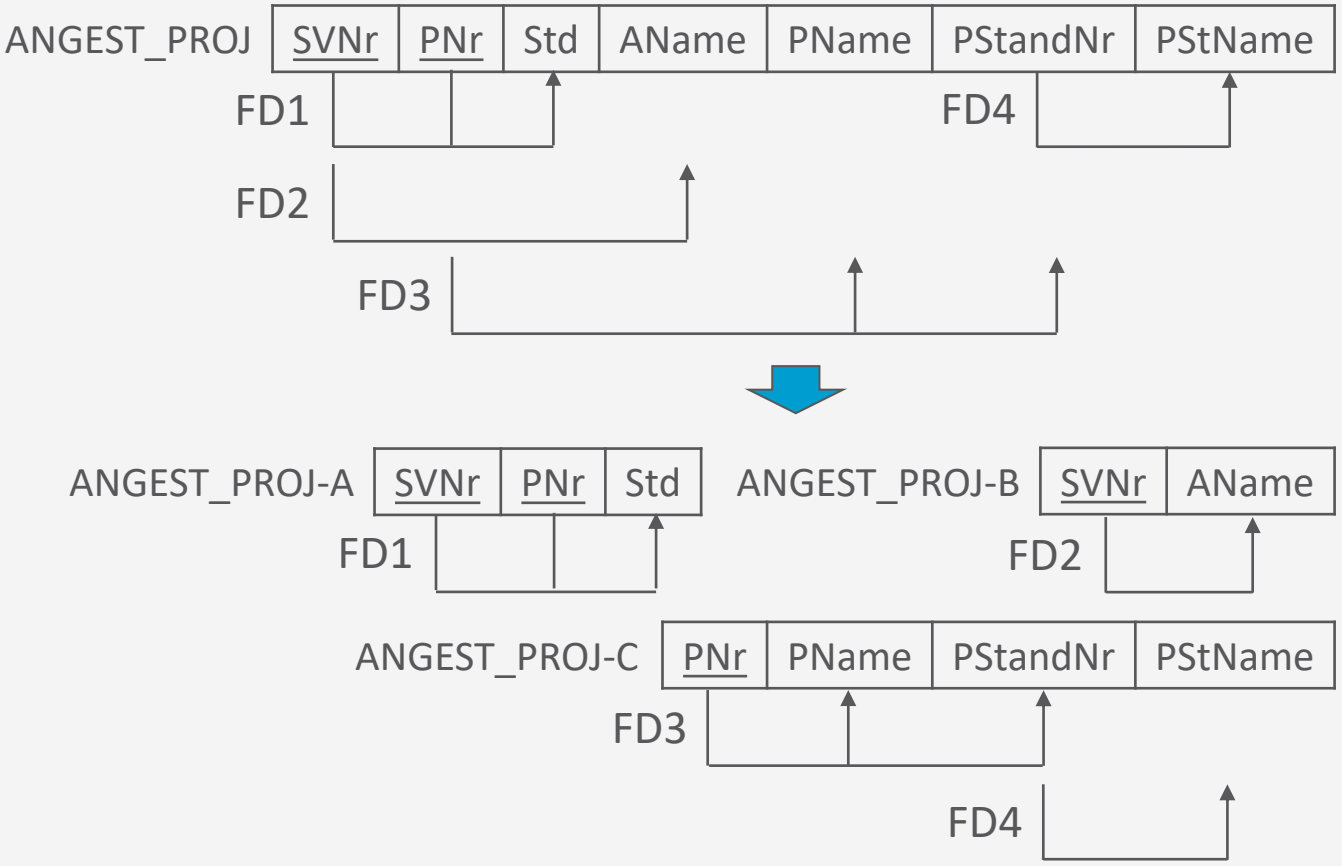

3. Normalform

- Relationenschema R ist in 3. Normalform (3NF), wenn
  - R in 2NF ist und
  - Kein nicht-primes Attribut von R transitiv von einem Schlüsselkandidaten abhängt
    - Keine so genannten *transitiven Abhängigkeiten*
- Erzeugung:
  - Zerlege das Relationenschema und erstelle ein neues, welches das nicht-prime Attribut bzw. die nicht-primen Attribute beinhaltet, die funktional von anderen nicht-primen Attributen bestimmt werden
    - Synthesealgorithmus

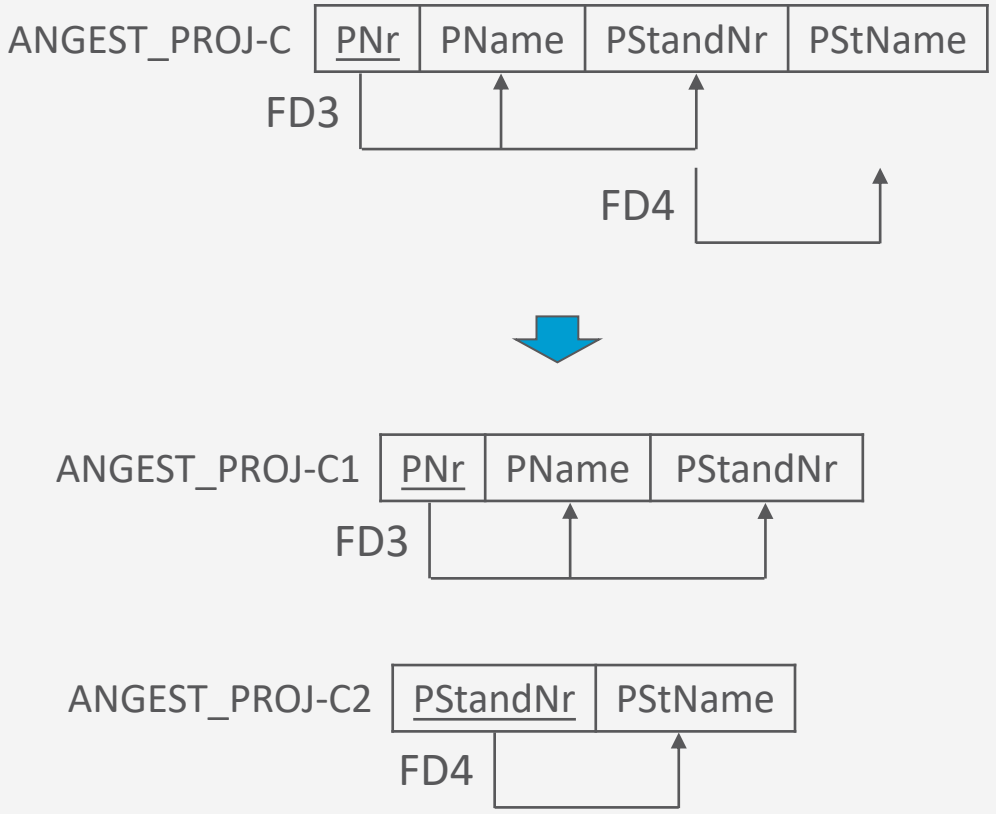

Synthesealgorithmus

- Ziel: abhängigkeitswahrende, verlustlose Zerlegung $D = \{R_1, \dots, R_m\}$ in Bezug auf eine Menge von FDs F eines Relationenschemas R, so dass jede Relation R_i in 3NF ist
- Input: Universal-Relationenschema R, Menge von FDs F für die Attribute von R
  - Universal-Relationenschema R als eine abstrakte Relation über alle betrachteten Attribute
- Output: Zerlegung $D = \{R_1, \dots, R_m\}$ von R
- 4 Schritte
  1. Bestimme eine kanonische Überdeckung F_C
  2. Erzeuge Relationenschemata für jede FD in F_C
  3. Stelle sicher, dass es ein Schema mit einem Schlüssel für R gibt
  4. Eliminiere doppelte Schemata

Synthesealgorithmus: Schritte

- Input: Universal-Relationenschema R, Menge von FDs F für die Attribute von R
- Output: Zerlegung $D = \{R_1, \dots, R_m\}$ von R
  1. Bestimme eine kanonische Überdeckung F_C für F
     - Linksreduktion, Rechtsreduktion, FDs mit leerem β löschen, FDs mit gleichem α zusammenfassen
  2. Für jede FD $\alpha \rightarrow \beta$ in F_C, erzeuge ein Relationenschema R_α in D mit Attributen $\alpha \cup \beta$
     - Ordne R_α die FDs aus F_C zu, deren Attribute in $\alpha \cup \beta$ sind: $F_\alpha = \{\alpha' \rightarrow \beta' | \alpha' \cup \beta' \subseteq \alpha \cup \beta\}$
     - α ist Schlüssel dieses Relationenschemas
  3. Wenn keines der resultierenden Relationenschemata in D einen Schlüssel von R enthält, dann erzeuge ein weiteres Relationenschema in D, das die Attribute enthält, die einen Schlüssel von R bilden: Wähle Schlüsselkandidat κ und definiere R_κ über κ mit $F_\kappa = \emptyset$
  4. Eliminiere diejenigen Schemata $R_{\alpha'}$ in D, die in einem anderen Schema R_α aus D enthalten sind, d.h. $R_{\alpha'} \subseteq R_\alpha$

Synthesealgorithmus: Beispiel

- Sei Relationenschema R mit funktionalen Abhängigkeiten F gegeben
  - $F = \{S \rightarrow NG, G \rightarrow K, SN \rightarrow RG\}$

1. Bestimme eine kanonische Überdeckung F_C von F
   - Ergebnis aus vorherigen Folien:
     $F_C = \{S \rightarrow NRG, G \rightarrow K\}$
2. Erzeuge Schemata für die FDs in F_C
   - $D = \{R_1, R_2\}$

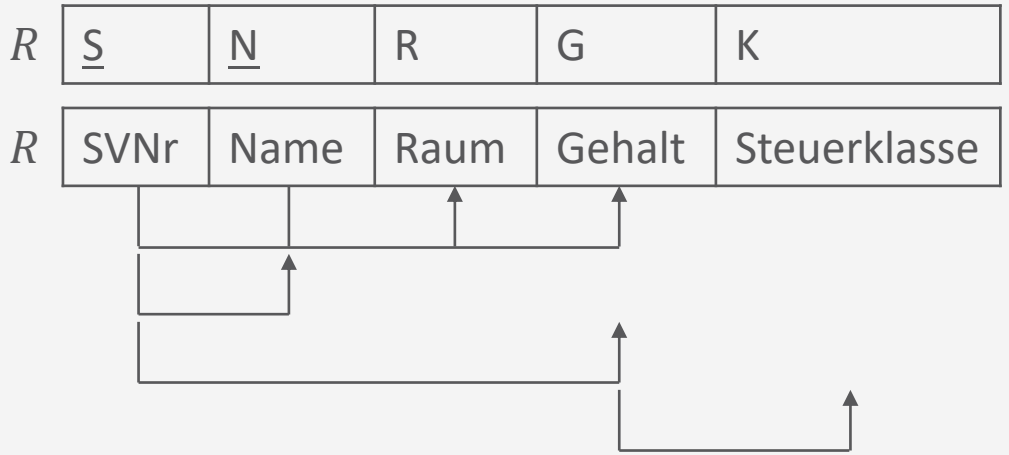

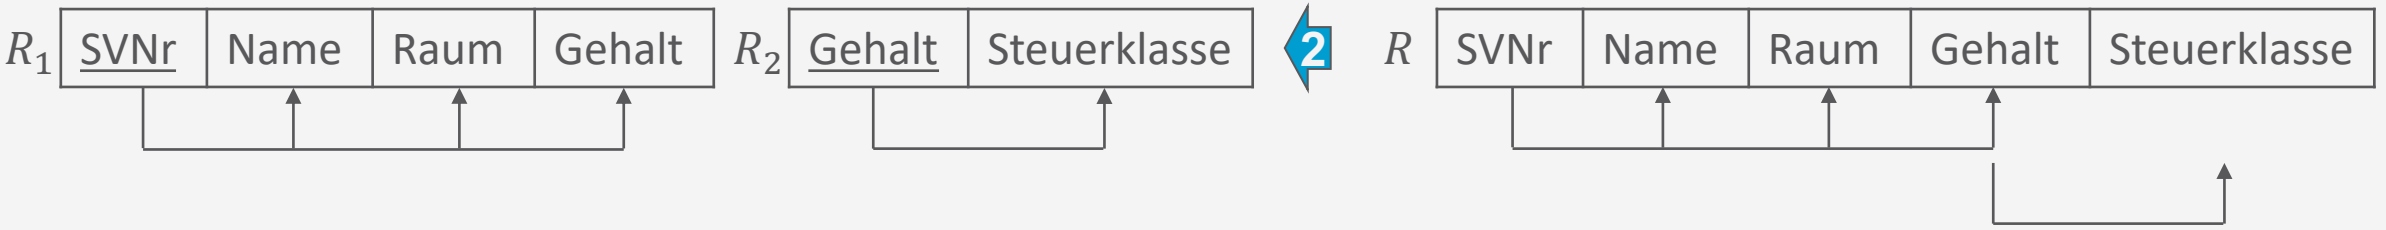

Synthesealgorithmus: Beispiel

- D nach Schritt 2

R_1	SVNr	Name	Raum	Gehalt	R_2	Gehalt	Steuerklasse

- Schritt 3: Abschließendes Relationenschema bei fehlendem Schlüssel
  - Wenn keines der Relationenschemata in D einen Schlüssel von R enthält, dann erzeuge ein weiteres Relationenschema in D, das Attribute enthält, die einen Schlüssel von R bilden.
    - Betrifft Attribute, die in keiner FD vorkommen
  - Beispiel: Schlüssel von R enthalten (keine Änderungen in D)
- Schritt 4: G reduzieren
  - Eliminiere diejenigen Schemata in D, die in einem anderen Schema aus D enthalten sind
  - Beispiel: R_1 und R_2 sind nicht im jeweils anderen enthalten (keine Änderungen in D)
    - D.h., der Algorithmus terminiert

3. Normalform

- Effekt:
  - Es gibt keine anderen Nicht-Schlüsselattribute, von denen ein nicht primes Attribut funktional abhängig ist
- Praktischer Nutzen:
  - Verbliebene thematische Durchmischung behoben (*Abgrenzung*)
  - Weitere *Reduktion redundanter Werte*
    - Weitere Vermeidung von Anomalien
    - Beispiel: Standortnamen nur einmal pro Standortnummer
- Die meisten 3NF-Schemata weisen in der Praxis keine dramatischen Probleme auf
  - Sorgfältige Erstellung, z.B., über ER-Diagramm

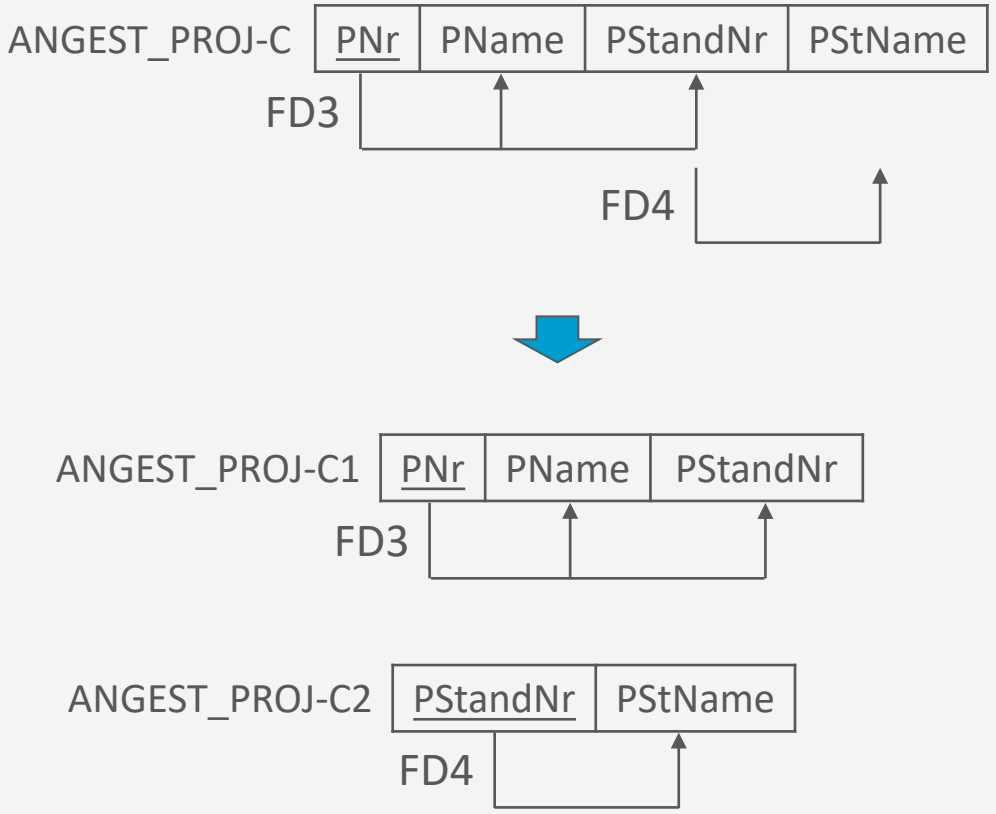

3. Normalform: Probleme

- Immer noch redundante Werte möglich → Anomalien möglich
  - Beispiel: $KUNDE(KNr, KName, Adr, VkNr, VkName)$
    - Abhängigkeiten:
      - FD1: $\{KNr\} \rightarrow \{KName, Adr, VkNr\}$
      - FD2: $\{VkNr\} \rightarrow \{VKName\}$
    - In 3NF:
      - $KUNDE(KNr, KName, Adr, VkNr)$
      - $VERKÄUFER(VkNr, VkName)$
    - Problem: Folgende Zerlegung ebenfalls in 3NF
      - $KUNDE(KNr, KName, Adr, VkNr)$
      - $VERKÄUFER1(KNr, VkName)$

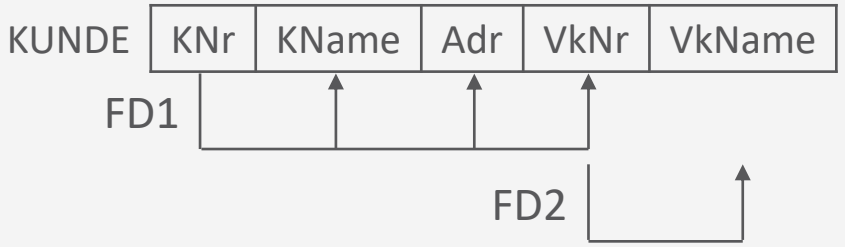

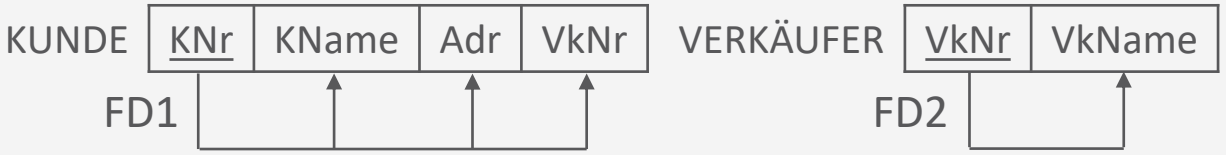

Was für Anomalien können entstehen?

3. Normalform: Probleme

- Fortsetzung Beispiel:
  - Erzeugt u.a. folgende Anomalien:
    - Änderungsaufwand: Änderung eines $VkName$ zu einer $VkNr$
    - Unvollständiges Einfügen: Einfügen eines neuen Verkäufers mit Nummer und Name, der noch keinen Kunden betreut
  - Ursache: FDs $\{KNr\} \rightarrow \{VkNr\}$ und $\{VkNr\} \rightarrow \{VkName\}$ werden auf zwei Relationen „transitiv“ verteilt
    - *IR3*: Wenn
      - $\{\{KNr\} \rightarrow \{VkNr\}, \{VkNr\} \rightarrow \{VKName\}\}$, dann
      - $\{KNr\} \rightarrow \{VKName\}$ (FD3)
  - Reine Erfüllung der NF kein gutes Maß

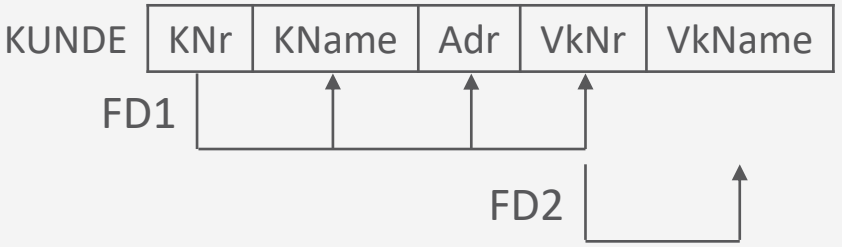

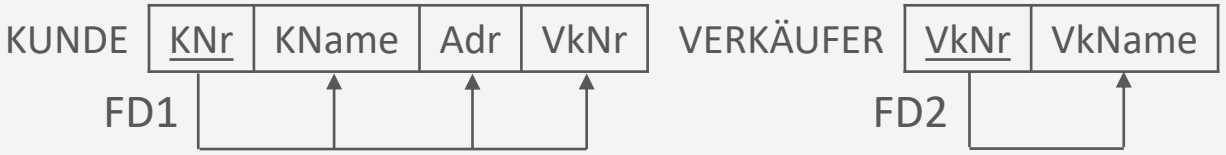

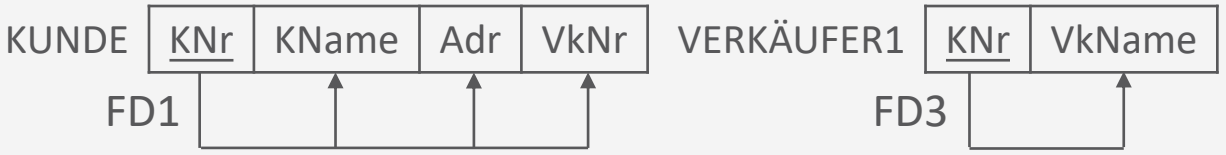

3. Normalform: Probleme

- Nicht-triviale Abhängigkeiten zwischen Attributen von Schlüsselkandidaten → Erzeugen ebenfalls Redundanzen
  - Beispiel: $RECHNUNG(RNr, KostenArt, KANr, Anzahl)$
    - Abhängigkeit zwischen $KostenArt, KANr$ (1:1-Beziehung)
    - Schlüsselkandidaten: $\{RNr, KostenArt\}, \{RNr, KANr\}$
    - In 3NF, da
      - In 2NF: jedes nicht-prime Attribut ($Anzahl$) ist voll funktional abhängig von allen Attributen der jeweiligen Schlüsselkandidaten
      - Keine transitiven Abhängigkeiten, da kein weiteres nicht-primes Attribut vorhanden
    - Aber:
      - Redundanzen durch Abhängigkeit zwischen $KostenArt, KANr$ → Anomalien möglich, z.B. wenn man eine Nummer zu einer Kostenart ändert

RECHNUNG	RNr	KostenArt	KANr	Anzahl

In 3NF ist es möglich, dass ein Teil eines (zusammengesetzten) Schlüsselkandidaten funktional abhängig ist von einem Teil eines anderen Schlüsselkandidaten.

Boyce-Codd-Normalform (BCNF)

- Relationenschema R ist in Boyce-Codd-Normalform (BCNF), wenn
  - R in 3NF ist und
  - Für jede nicht-triviale funktionale Abhängigkeit $X \rightarrow A$ in R gilt:

    X ist ein Superschlüssel von R
- Erzeugung:
  - Für eine nicht-triviale Abhängigkeit $X \rightarrow A$, die die BCNF verletzt (X kein Superschlüssel), erzeuge eine neue Relation über Attribute X, A mit X als Schlüssel und lösche A aus R
    - Zerlegungsalgorithmus

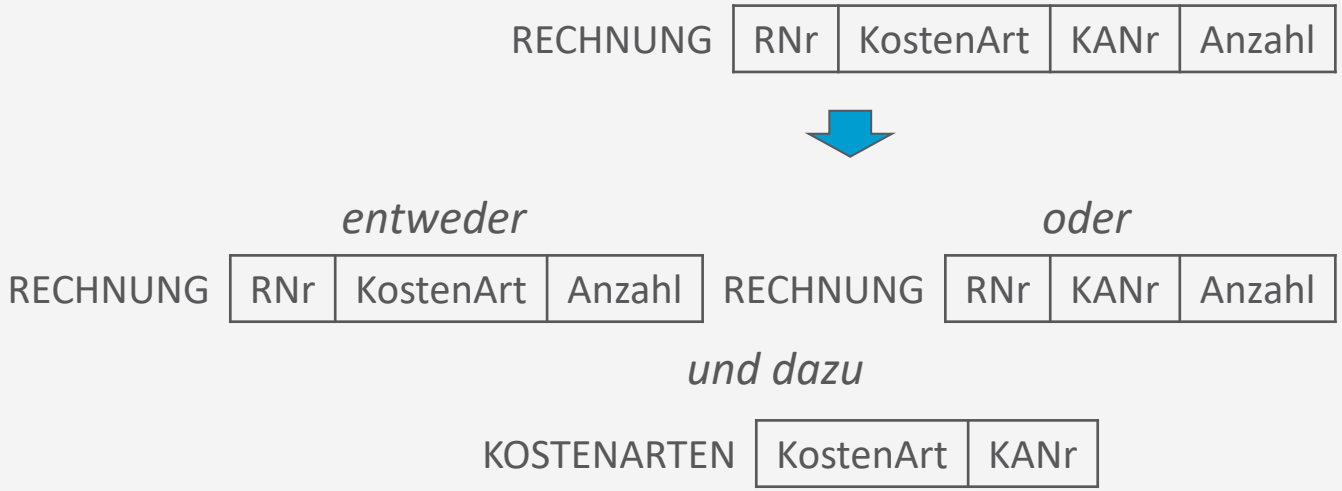

Zerlegungsalgorithmus

- Eingabe: Relationenschema R und Menge von zugehörigen FDs F
- Ausgabe: Zerlegung $D = \{R_1, \dots, R_n\}$, wobei jedes R_i in BCNF ist
- Starte mit $D = \{R\}$
- Solange es noch ein Relationenschema R_i in D gibt, das nicht in BCNF ist:
  - Finde eine FD $\alpha \rightarrow \beta$, die einem R_i zugehörig ist, mit
    1. $\alpha \cap \beta = \emptyset$
    2. $\neg(\alpha \rightarrow R_i)$
    - Man sollte $\alpha \rightarrow \beta$ so wählen, dass β alle von α funktional abhängigen Attribute $B \in (R_i - \alpha)$ enthält, damit der Zerlegungsalgorithmus möglichst schnell terminiert
  - Zerlege R_i in $R_{i1} \leftarrow \alpha \cup \beta$ und $R_{i2} \leftarrow R_i - \beta$
  - Entferne R_i aus D und füge R_{i1} und R_{i2} ein, also
    - $D \leftarrow (D - \{R_i\}) \cup \{R_{i1}, R_{i2}\}$

Beispiele

- Zerlegung ANGEST_PROJ
  - FD4 erfüllt $\neg(\alpha \rightarrow R_i)$:
    - ANGEST_PROJ-C2 → in BCNF
    - ANGEST_PROJ'(SVNr, PNr, Std, AName, Pname, PStandNr)
  - FD3 erfüllt $\neg(\alpha \rightarrow R_i)$ in ANGEST_PROJ':
    - ANGEST_PROJ-C1 → in BCNF
    - ANGEST_PROJ''(SVNr, PNr, Std, AName)
  - FD2 erfüllt $\neg(\alpha \rightarrow R_i)$ in ANGEST_PROJ'':
    - ANGEST_PROJ-B(SVNr, AName) → in BCNF
    - ANGEST_PROJ-A(SVNr, PNr, Std) → in BCNF

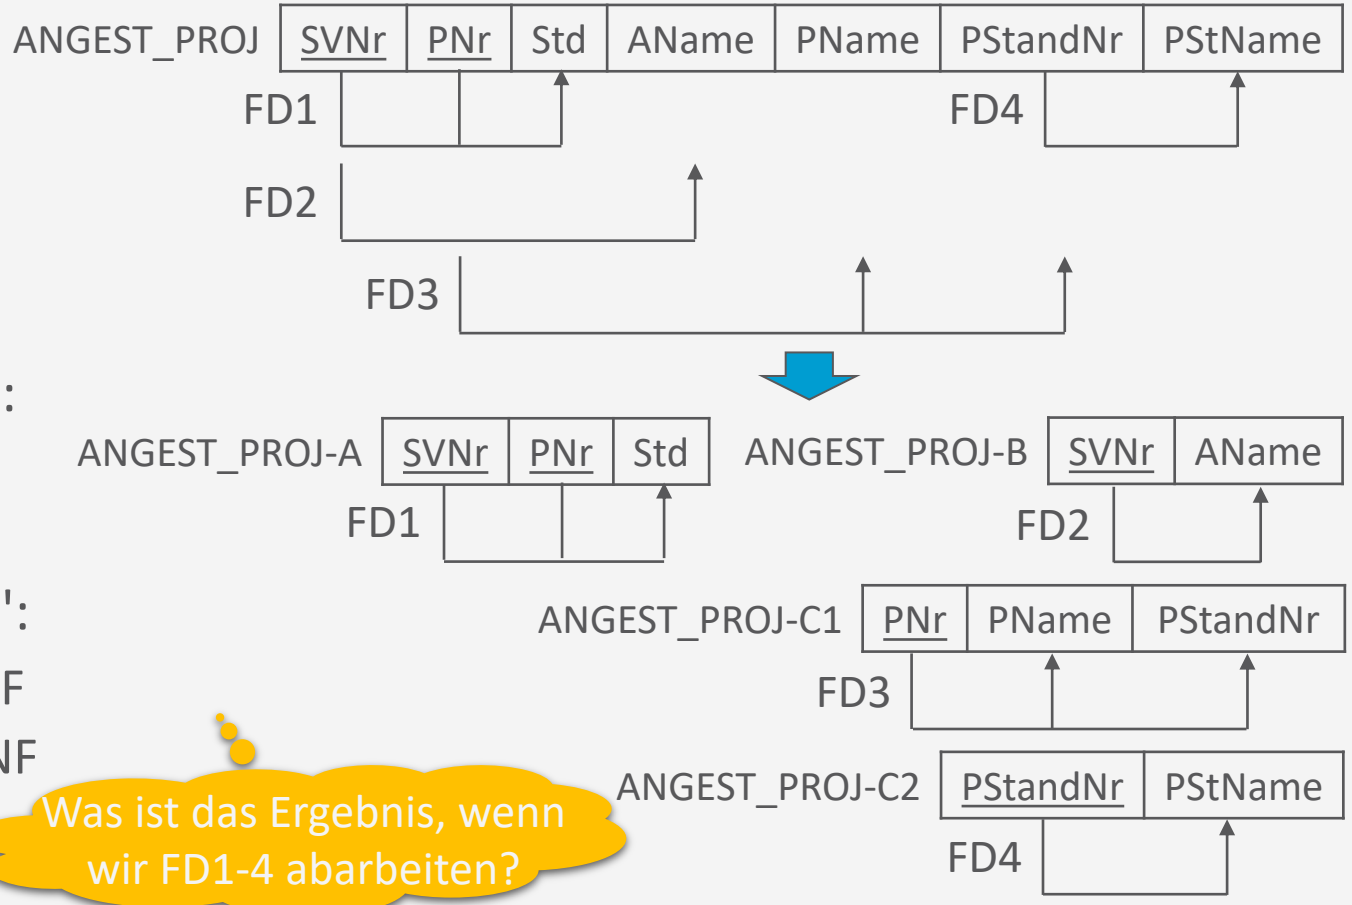

Boyce-Codd-Normalform (BCNF)

- Relation lässt sich immer in BCNF bringen
  - Dann keine Redundanzen mehr
  - Verlustlos
- Aber: Nicht jedes 3NF Schema in BCNF überführbar bei gleichzeitiger Wahrung der Abhängigkeiten
  - Damit keine effiziente Überprüfung der Abhängigkeiten möglich
    - Beispiel: Man erhält nicht mehr ohne Join die PLZ zu Straße und Ort

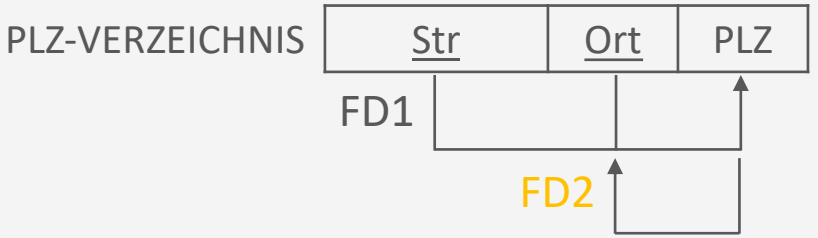

PLZ kein Superschlüssel

Str	Ort	PLZ
Baumstr	Biel	2500
Parkstr	Bern	3000
Wiesenstr	Bern	3018
Baumstr	Bern	3018

FD1 geht verloren!

Str	PLZ
Baumstr	2500
Parkstr	3000
Wiesenstr	3018
Baumstr	3018

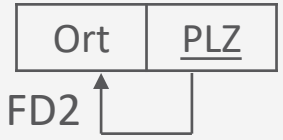

Ort	PLZ
Biel	2500
Bern	3000
Bern	3018

BCNF und 3NF

- Unterschied zwischen 3NF und BCNF nur bei mehreren Schlüsselkandidaten mit überlappenden Attributen
- Relation in BCNF hat garantiert keine Redundanzen
  - Im Gegensatz zu Relation in 3NF

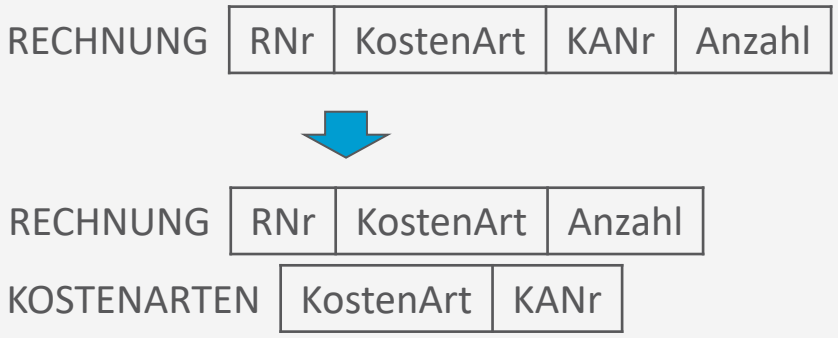

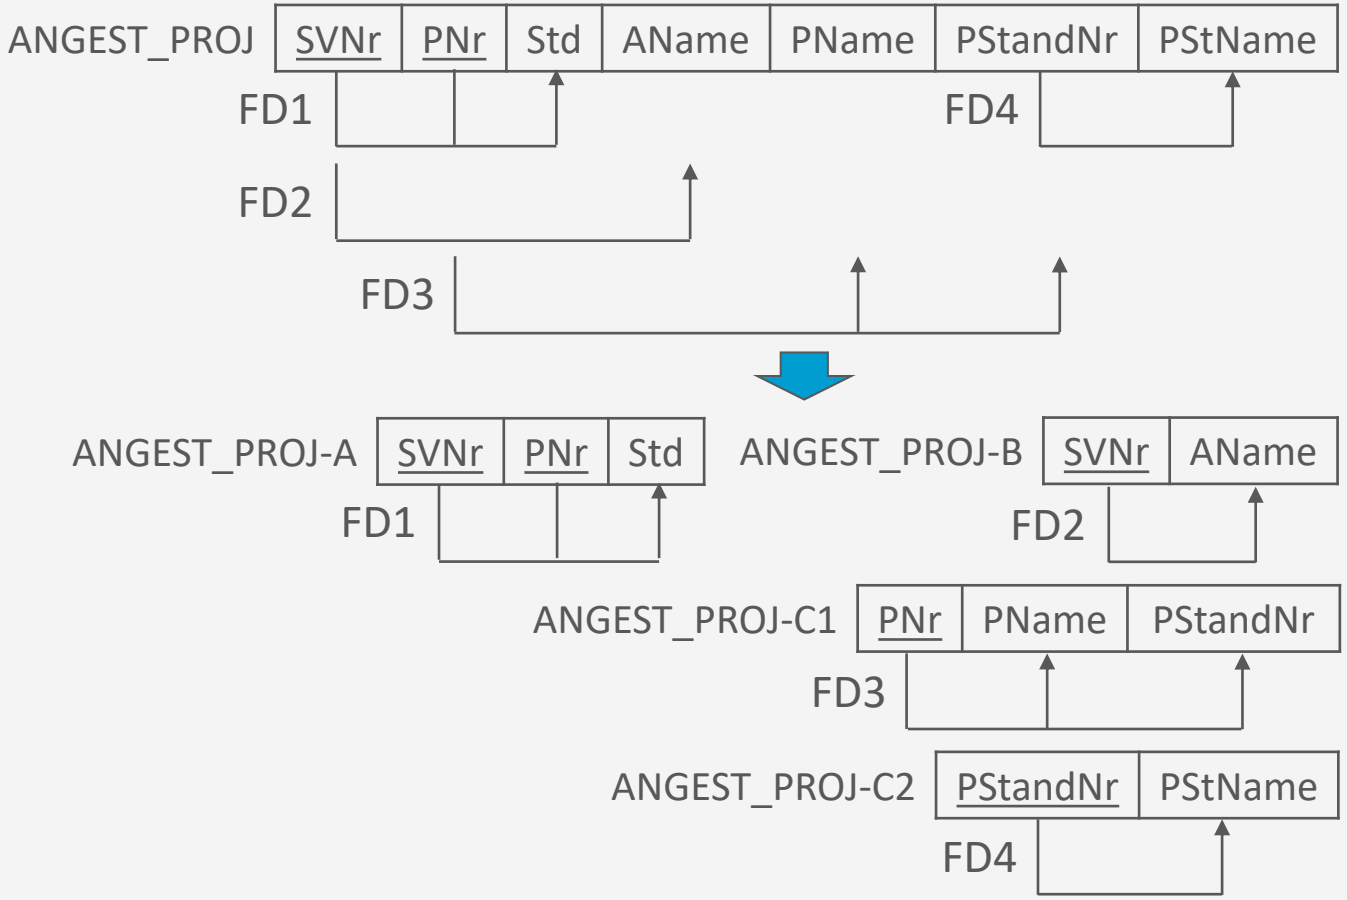

Höhere Normalformen

- 4. Normalform (4NF): Keine mehrwertigen Abhängigkeiten (*multi-valued dependencies*, MVDs)
  - Falls in einem Relationenschema $R(A_1, \ldots, A_n)$ wenigstens zwei 1:n-Beziehungen der Form $A_i: A_j$ und $A_i: A_k$ existieren, bei denen A_j und A_k „unabhängig“ sind, dann kann eine MVD entstehen
    → zu zerlegen für 4NF
  - Beispiel
    - Ein Angestellter arbeitet an Projekten und hat Angehörige. Er kann an mehreren Projekten arbeiten und ebenfalls mehrere Angehörige haben. Projekte und Angehörige sind aber voneinander unabhängig.
    - In $ANGEST$ sind die beiden 1:n-Beziehungen in einer Relation, bei $ANGEST\_PROJ, ANGEST\_ANG$ auf zwei Relationen verteilt

ANGEST

AName	PName	AAName
Smith	P1	John
Smith	P2	Anna
Smith	P1	Anna
Smith	P2	John

ANGEST_PROJ

AName	PName
Smith	P1
Smith	P2

ANGEST_ANG

AName	AAName
Smith	John
Smith	Anna

Höhere Normalformen

- 5. Normalform (5NF)
  - Es gibt Fälle, in denen eine nicht-additive JOIN-Zerlegung eines Schemas R in zwei Relationenschemata nicht möglich ist, aber in drei oder mehr
  - Beispiel:
    - Zerlegung von R in zwei Schemata nicht möglich (unechte Tupel)
    - Nicht-additive JOIN-Zerlegung in R_1, R_2 und R_3 möglich
      - Man sagt auch: „JOIN-Abhängigkeit“ verhindern

R

Repräsentant	Firma	Produkt
Schmidt	Ford	PKW
Schmidt	Ford	LKW
Schmidt	VW	Transporter
Müller	Porsche	PKW
Müller	Ford	PKW

R_1

Repräsentant	Firma
Schmidt	Ford
Schmidt	VW
Müller	Porsche
Müller	Ford

R_2

Repräsentant	Produkt
Schmidt	PKW
Schmidt	LKW
Schmidt	Transporter
Müller	PKW

R_3

Firma	Produkt
Ford	PKW
Ford	LKW
VW	Transporter
Porsche	PKW

Die 5. Normalform – Motivation

- Beispiel (Test 1): JOIN über R_1 und R_2 (Join-Prädikat Repräsentant)

R

	Repräsentant	Firma	Produkt
	Schmidt	Ford	PKW
	Schmidt	Ford	LKW
*	Schmidt	Ford	Transporter
*	Schmidt	VW	PKW
*	Schmidt	VW	LKW
	Schmidt	VW	Transporter
	Müller	Porsche	PKW
	Müller	Ford	PKW

* unechte Tupel

$R_1 \bowtie R_2$

R_1

Repräsentant	Firma
Schmidt	Ford
Schmidt	VW
Müller	Porsche
Müller	Ford

R_2

Repräsentant	Produkt
Schmidt	PKW
Schmidt	LKW
Schmidt	Transporter
Müller	PKW

R_3

Firma	Produkt
Ford	PKW
Ford	LKW
VW	Transporter
Porsche	PKW

Die 5. Normalform – Motivation

- Beispiel (Test 2): JOIN über R_1 und R_3 (Join-Prädikat Firma)

R

	Repräsentant	Firma	Produkt
	Schmidt	Ford	PKW
	Schmidt	Ford	LKW
	Schmidt	VW	Transporter
	Müller	Porsche	PKW
	Müller	Ford	PKW
*	Müller	Ford	LKW

* unechte Tupel

$R_1 \bowtie R_3$

R_1

Repräsentant	Firma
Schmidt	Ford
Schmidt	VW
Müller	Porsche
Müller	Ford

R_2

Repräsentant	Produkt
Schmidt	PKW
Schmidt	LKW
Schmidt	Transporter
Müller	PKW

R_3

Firma	Produkt
Ford	PKW
Ford	LKW
VW	Transporter
Porsche	PKW

Die 5. Normalform – Motivation

- Beispiel (Test 3): JOIN über R_2 und R_3 (Join-Prädikat Produkt)

R

	Repräsentant	Firma	Produkt
	Schmidt	Ford	PKW
*	Schmidt	Porsche	PKW
	Schmidt	Ford	LKW
	Schmidt	VW	Transporter
	Müller	Porsche	PKW
	Müller	Ford	PKW

* unechte Tupel

$R_2 \bowtie R_3$

R_1

Repräsentant	Firma
Schmidt	Ford
Schmidt	VW
Müller	Porsche
Müller	Ford

R_2

Repräsentant	Produkt
Schmidt	PKW
Schmidt	LKW
Schmidt	Transporter
Müller	PKW

R_3

Firma	Produkt
Ford	PKW
Ford	LKW
VW	Transporter
Porsche	PKW

Die 5. Normalform – Motivation

- Beispiel (Test 4): JOIN über R_1, R_2 und R_3

R

Repräsentant	Firma	Produkt
Schmidt	Ford	PKW
Schmidt	Ford	LKW
Schmidt	VW	Transporter
Müller	Porsche	PKW
Müller	Ford	PKW

$$R_1 \bowtie R_2 \bowtie R_3$$

R_1

Repräsentant	Firma
Schmidt	Ford
Schmidt	VW
Müller	Porsche
Müller	Ford

R_2

Repräsentant	Produkt
Schmidt	PKW
Schmidt	LKW
Schmidt	Transporter
Müller	PKW

R_3

Firma	Produkt
Ford	PKW
Ford	LKW
VW	Transporter
Porsche	PKW

Normalisierung und die Praxis

- Aus Performance-Gründen manchmal keine Normalisierung

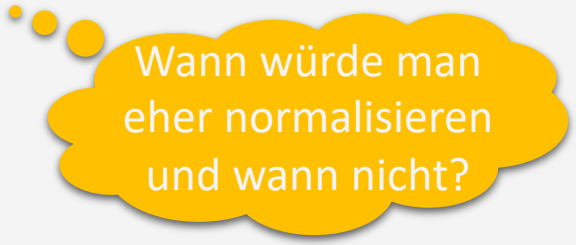

- Gründe gegen Normalisierung, z.B.
  - Zerlegung kann häufige JOINs erfordern
    - Wenn Dinge immer wieder vorkommen, ist es vielleicht sinnvoll die JOIN Tabelle zu speichern, auch wenn es Redundanzen gibt
  - Wenn es kaum Änderungen am Datensatz gibt, dann sind Redundanzen nicht so tragisch

- Gründe für Normalisierung, z.B.
  - Häufiger Änderungen
    - Abwägung zwischen Redundanzfreiheit und Abhängigkeitswahrung, sollte nur eins von beiden gehen

Zwischenzusammenfassung

- Korrektheitskriterien für Zerlegungen: Verlustlose Zerlegung, Abhängigkeitswahrung
  - Dazu: Vermeidung von Redundanzen
- Normalformen
  - (NF^2), 1NF, 2NF, 3NF, BCNF, 4NF, 5NF
  - Synthesealgorithmus liefert verlustfreie, abhängigkeitswahrende Zerlegung mit Schemata in 3NF; Redundanzen möglich
  - Zerlegungsalgorithmus liefert verlustfreie Zerlegung ohne Redundanzen mit Schemata in BCNF, aber nicht immer abhängigkeitswahrend

Abhängigkeitserhaltende Zerlegung (bis 3NF)

Verlustlose Zerlegung (bis 5NF)

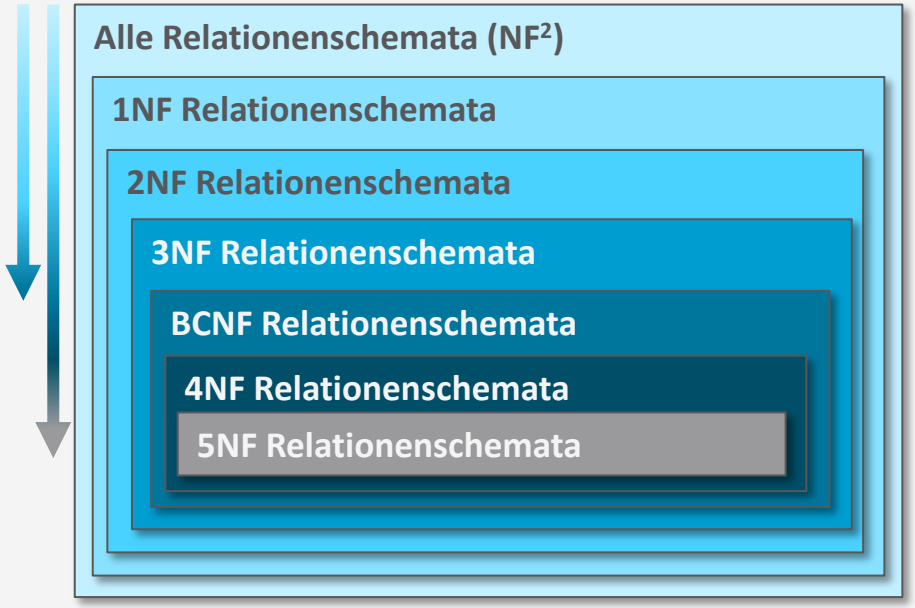

Überblick: 4. Datenbankentwurf

A. Funktionale Abhängigkeiten

- Definition, Schlüssel, Ableitungen
- Attributhülle, kanonische Überdeckung

B. Normalformen

- Zerlegung von Relationen
- Exkurs: NF^2; 1NF, 2NF, 3NF, BCNF, 4NF, 5NF
- Synthesealgorithmus, Zerlegungsalgorithmus

C. Datenqualität

- Datenqualitätsprobleme, Dimensionen der Datenqualität

Problemfeld Datenqualität

- Normalformen zielen auf die strukturelle Qualität von Relationenschemata
  - „Intension“
- Datenqualität umfasst Beiträge zur Verbesserung der konkreten „inhaltlichen“ Dateninstanzen auf der Schemaebene
  - „Extension“
- Der Aspekt der Datenqualität ist als problematisch einzuschätzen, wenn Daten vor dem Hintergrund einer Anwendungssituation, z.B.
  - Nicht die angenommene Bedeutung haben
  - Nicht der Spezifikation entsprechen
  - Unverständlich sind

Beispiele für mindere Datenqualität

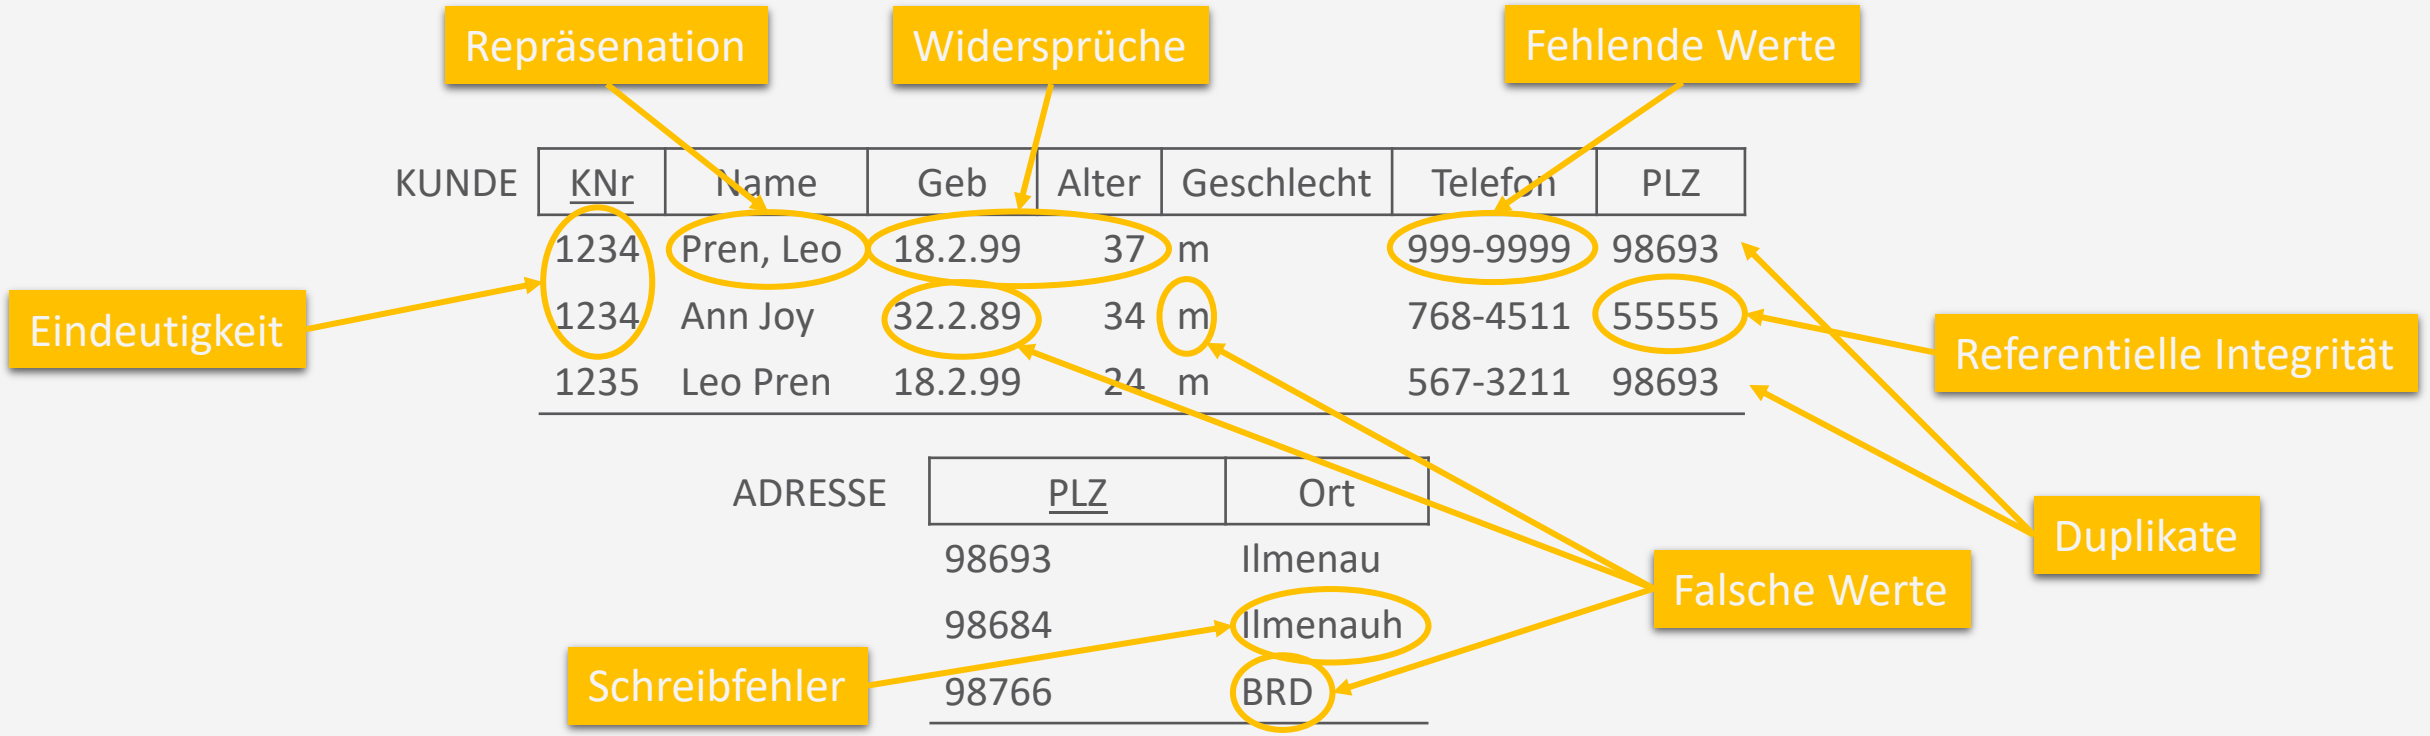

(Quelle: K. Sattler; DB-Tutorientage 2005)

Ursachen für Datenqualitätsprobleme

- Ursachen liegen auf verschiedenen Ebenen, u.a. bei der
  - Datenproduktion, z.B.
    - Verschiedene Quellen repräsentieren gleiche Realwelt-Objekte in unterschiedlicher Form
    - Datenerfassung unterliegt „subjektiven Einflüssen“
    - Systematische Probleme bei Datenerfassung (Messung, Kodierung etc.)
  - Datenspeicherung, z.B.
    - Unterschiedliche oder ungeeignete Formate
  - Datennutzung, z.B.
    - Unzureichende Analyse- und Verarbeitungsmöglichkeiten
    - Veränderung der Nutzungsbedürfnisse
    - Sicherheits- und Zugriffsprobleme

(Quelle: K. Sattler; DB-Tutorientage 2005)

Arten von Datenqualitätsproblemen

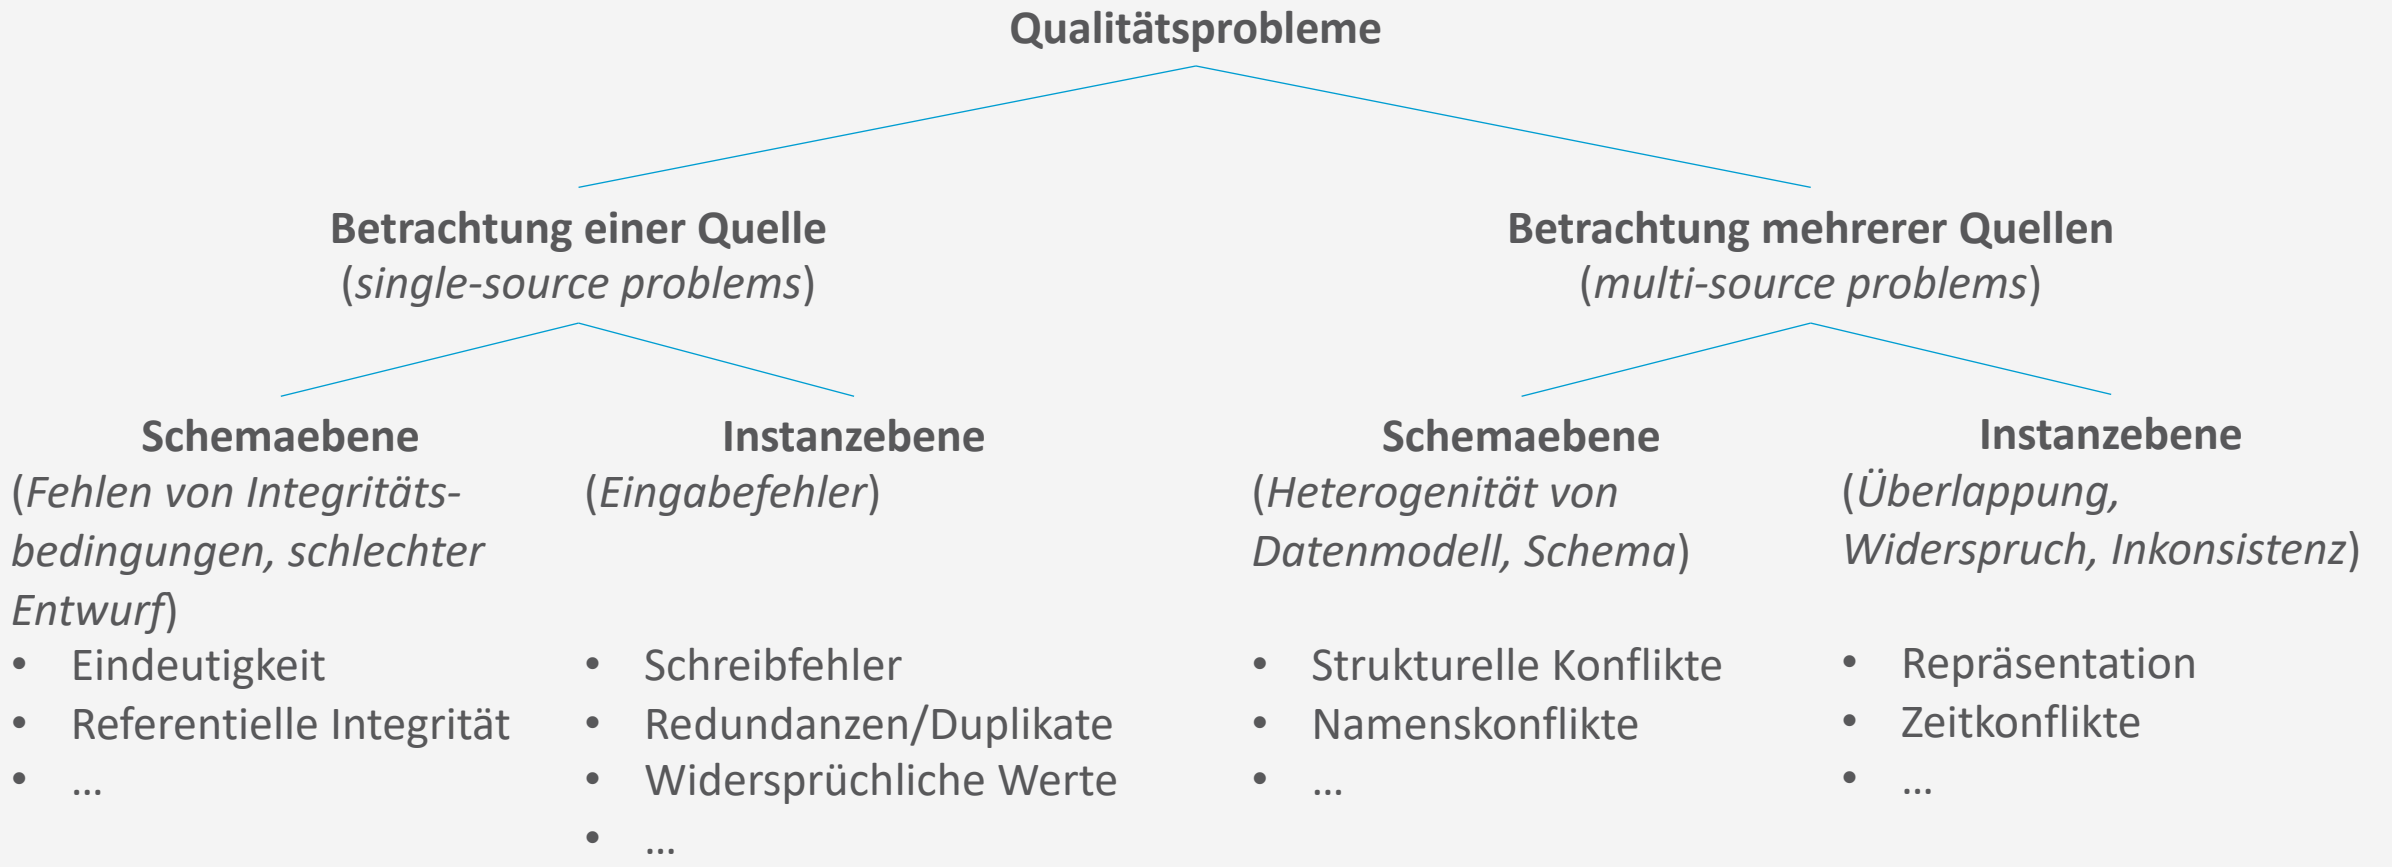

(Quelle: K. Sattler; DB-Tutorientage 2005)

Dimensionen der Datenqualität

- Datenqualität wird anhand verschiedener Dimensionen beurteilt, z.B.
  - Vollständigkeit: Verhältnis tatsächlicher Werte zu gespeicherten Werten, u.a.
    - Wertebelegungen verschieden von Null
    - Repräsentation aller in der Realwelt vorkommenden Objekte
  - Genauigkeit: Verhältnis der Anzahl der korrekten Werte zur Gesamtanzahl, d.h. prozentualer Anteil an Daten ohne Datenfehler
    - Umfang, in dem Attributwerte im jeweils „optimalen“ Detaillierungsgrad vorliegen
    - Nähe eines Wertes zum korrekten Wert innerhalb der Realwelt
  - Zeitnähe: Aktualität, in der Attributwerte dem sich dynamisch ändernden Realwelt-Zustand entsprechen
    - Alter: Zeit seit dem Erfassen / Laden der Daten
    - Volatilität: Häufigkeit der Änderungen

(Quelle: K. Sattler; DB-Tutorientage 2005)

Dimensionen der Datenqualität (Fortsetzung)

- Weitere Dimensionen, u.a.
  - Relevanz: Grad, in dem der Informationsgehalt den Nutzungsbedürfnissen entspricht
  - Verständlichkeit: Grad, in dem Daten in Inhalt und Struktur mit der „Vorstellungswelt“ der nutzenden Personen übereinstimmen
  - Konsistenz: Grad, in dem Daten frei von logischen Widersprüchen sind
    - Integritätsbedingungen, Geschäftsregeln, ...
  - Verfügbarkeit: Grad, in dem Daten für nutzende Personen in einem bestimmten Zeitraum nutzbar sind
  - Glaubwürdigkeit: Grad, in dem Daten von nutzenden Personen als korrekt akzeptiert werden
  - Kosten: Preis für Datenzugriff, Anfrage, Datenübertragung, ...

(Quelle: K. Sattler; DB-Tutorientage 2005)

Zwischenzusammenfassung

- Normalformen: strukturelle Qualität, Datenqualität: Qualität der Dateninstanzen
- Ursachen von Datenqualitätsproblemen
  - Verschiedene Quellen, subjektive oder systematische Einflüsse bei der Datenerfassung
  - Unterschiedliche / falsche Formate
  - Veränderte Anforderungen, Sicherheits- und Zugriffsprobleme
- Arten von Datenqualitätsproblemen
  - Eindeutigkeit, referentielle Integrität, Schreibfehler, Redundanzen / Duplikate, Widersprüche
  - Namenskonflikte, strukturelle Konflikte, Repräsentation
- Dimension Beurteilung
  - Vollständigkeit, Genauigkeit, Zeitnähe, Relevanz, Verständlichkeit, Konsistenz, Verfügbarkeit, Glaubwürdigkeit, Kosten

Überblick: 4. Datenbankentwurf

A. Funktionale Abhängigkeiten
- Definition, Schlüssel, Ableitungen
- Attributhülle, kanonische Überdeckung

B. Normalformen
- Zerlegung von Relationen
- Exkurs: NF^2; 1NF, 2NF, 3NF, BCNF, 4NF, 5NF
- Synthesealgorithmus, Zerlegungsalgorithmus

C. Datenqualität
- Datenqualitätsprobleme, Dimensionen der Datenqualität

→ Structured Query Language (SQL)