

Grundlagen der Datenbanken

Relationale Entwurfstheorie

Dr. Jérôme Kunegis

Wintersemester 2012/13



Lernziele

- Charakterisierung "guter" relationaler Schemata:
 - jede Relation entspricht genau einer Objektmenge - eventuell unter Einbezug von N:1- oder 1:1-Relationships - oder genau einer Relationship-Menge zwischen Objekten
 - Redundanz ist eliminiert, alle Informationen sind repräsentierbar, und es treten keinerlei "Änderungsanomalien" auf
 - a) Änderungen können bei Beachtung der Primärschlüssel- und Fremdschlüsselbedingung keine Inkonsistenzen hervorrufen
 - b) alle Informationen lassen sich unter Wahrung der Primärschlüssel- und Fremdschlüsselbedingung (ohne "Kunstgriffe") einfügen
 - c) Informationen können einzeln wieder gelöscht werden, ohne die Primärschlüssel oder Fremdschlüsselbedingung zu verletzen
- Algorithmische Herleitung solcher "guter" Schemata

Beispiel: "Schlechte" Relationenschemata

<i>ProfVorl</i>						
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	Schlick	C3	52	5259	Der Wiener Kreis	2
2137	Kant	C4	7	4630	Die 3 Kritiken	4



Beispiel: "Schlechte" Relationenschemata

<i>ProfVorl</i>						
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	Schlick	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?

Gliederung

- Funktionale Abhängigkeiten
- Dekomposition der Relationenschemata:
Verlustlosigkeit und Abhängigkeitsbewahrung
- Normalformen als Gütekriterium
- Erste Normalform
- Zweite Normalform
- Dritte Normalform, Zerlegung mit dem Synthesealgorithmus
- Boyce–Codd Normalform (BCNF), Dekompositions-Algorithmus

Relationenmodell revisited: Definitionen

Gegeben sei eine Menge von Wertebereichen primitiver Datentypen $\{D_1, \dots, D_m\}$, die als "**Domains**" bezeichnet werden.

Eine **Relation** R ist ein Paar $R = (s, v)$ mit

- einem **Schema** $s = sch(R) = \{A_1, \dots, A_n\}$, das aus einer Menge von **Attributen (Attributnamen)** besteht und für jedes Attribut A_i einen Domain $dom(A_i) \in \{D_1, \dots, D_m\}$ festlegt, und
- einer **Ausprägung**
 $v = val(R) \subseteq dom(A_1) \times dom(A_2) \times \dots \times dom(A_n)$.

Funktionale Abhängigkeiten (FD)

Schema $R = \{A, B, C, D\}$

Ausprägung Q

Seien $\alpha \subseteq R$, $\beta \subseteq R$

$\alpha \rightarrow \beta$ (gesprochen: α bestimmt β) genau dann wenn

$$\forall r, s \in Q (r.\alpha = s.\alpha \Rightarrow r.\beta = s.\beta)$$

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

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

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

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

Notationskonvention:

$CD \rightarrow B$

Beispiel

<i>Stammbaum</i>				
Kind	Vater	Mutter	Opa	Oma
Sofie	Alfons	Sabine	Lothar	Linde
Sofie	Alfons	Sabine	Hubert	Lisa
Niklas	Alfons	Sabine	Lothar	Linde
Niklas	Alfons	Sabine	Hubert	Lisa
...	Lothar	Martha
...



Beispiel

<i>Stammbaum</i>				
Kind	Vater	Mutter	Opa	Oma
Sofie	Alfons	Sabine	Lothar	Linde
Sofie	Alfons	Sabine	Hubert	Lisa
Niklas	Alfons	Sabine	Lothar	Linde
Niklas	Alfons	Sabine	Hubert	Lisa
...	Lothar	Martha
...

Kind → Vater, Mutter

Kind, Opa → Oma

Kind, Oma → Opa

Schlüssel



$\alpha \subseteq R$ ist ein **Super-Schlüssel**, falls folgendes 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, d.h.

$$\forall A \in \alpha (\neg((\alpha - \{A\}) \rightarrow \beta))$$

Notation für volle funktionale Abhängigkeit: $\alpha \rightarrow^{\bullet} \beta$

$\alpha \subseteq R$ ist ein **Kandidaten-Schlüssel**, falls folgendes gilt:

- $\alpha \rightarrow^{\bullet} R$

Attribut B heißt **Schlüsselattribut**, wenn B in einem von Kandidaten-Schlüsseln $\alpha \subseteq R$ vorkommt

Schlüsselbestimmung

<i>Städte</i>			
Name	Bundesland	Vorwahl	Einwohner
Frankfurt	Hessen	069	650.000
Frankfurt	Brandenburg	0335	84.000
München	Bayern	089	1.200.000
Mülheim-Kärlich	RLP	0261	10.416
Koblenz	RLP	0261	106.681

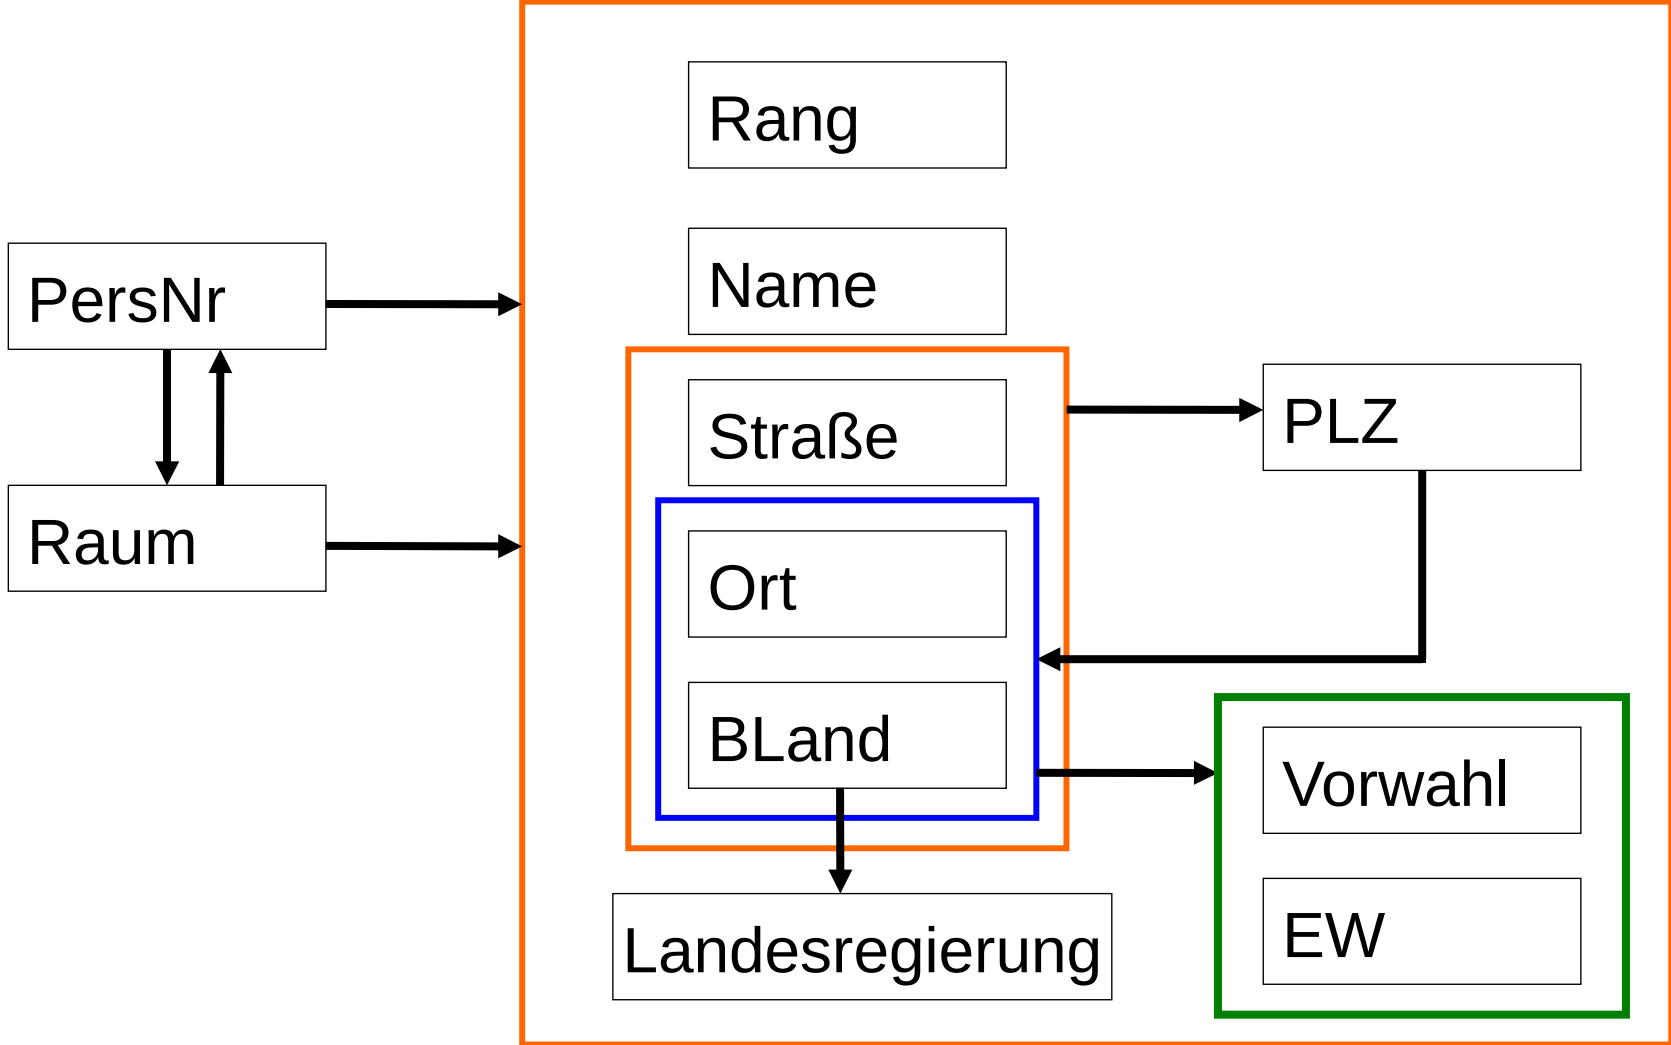
Kandidaten-schlüssel von *Städte*:

- {Name, Bundesland}
- {Name, Vorwahl}

Keine Kandidaten-Schlüssel:

- {Vorwahl}, {Name}, {Einwohner, Bundesland}

Graphische Darstellung der funktionalen Abhängigkeiten



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 $\alpha\gamma \rightarrow \beta\gamma$. ($\alpha\gamma$ steht hier 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.

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 $\alpha\gamma \rightarrow \delta$

Bestimmung der Hülle einer Attributmenge

Eingabe:

eine Menge F von funktionalen Abhängigkeiten (FD) und eine Menge von Attributen α .

Ausgabe:

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

AttrHülle (F, α)

result := α

WHILE (Änderungen an result) **DO**

FOREACH FD $\beta \rightarrow \gamma$ **IN** F **DO**

IF $\beta \subseteq$ result **THEN** result := result \cup γ

Ausgabe $\alpha^+ =$ result

Transitive Hülle der FDs

Gegeben sei eine Menge F von FDs

Die Menge aller aus F logisch ableitbaren FDs
wird als **transitive Hülle** F^+ bezeichnet

Satz:

Sei R eine Relation mit einer Menge F von FDs.

Durch endlich-malige Anwendung von Armstrong-Regeln
lassen sich genau alle Funktionalabhängigkeiten in F^+ herleiten

Die Armstrong-Regeln bilden also einen korrekten und vollständigen
Ableitungskalkül für die FDs in F^+

Bestimmung funktionaler Abhängigkeiten

Professoren: { PersNr, Name, Rang, Raum, Ort, Straße,
PLZ, Vorwahl, BLand, EW, Landesregierung }

- {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}

Kanonische Überdeckung

F_c heißt **kanonische Überdeckung** von F ,
wenn die folgenden drei Kriterien erfüllt sind:

1. $F_c \equiv F \Leftrightarrow F_c^+ = F^+$

1. In F_c existieren keine FDs $\alpha \rightarrow \beta$, die überflüssige Attribute enthalten:

$$\forall A \in \alpha \ (F_c - (\alpha \rightarrow \beta) \cup ((\alpha - \{A\}) \rightarrow \beta)) \not\equiv F_c$$

$$\forall B \in \beta \ (F_c - (\alpha \rightarrow \beta) \cup ((\alpha \rightarrow (\beta - \{B\}))) \not\equiv F_c)$$

1. Jede linke Seite einer funktionalen Abhängigkeit in F_c ist einzigartig.

Erreichbar durch sukzessive Anwendung der Vereinigungsregel:

$$\alpha \rightarrow \beta \quad \text{und} \quad \alpha \rightarrow \gamma \quad \text{zu} \quad \alpha \rightarrow \beta\gamma$$

Berechnung der kanonischen Überdeckung

1) Führe für jede FD $\alpha \rightarrow \beta \in F$ die **Linksreduktion** durch:

- 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 $(\alpha - A) \rightarrow \beta$.

2) Führe für jede (verbliebene) FD die **Rechtsreduktion** durch:

- Überprüfe für alle $B \in \beta$, ob $B \in \text{AttrHülle}(F - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B)), \alpha)$ gilt.

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

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

4) **Fasse** mittels der Vereinigungsregel FDs der Form $\alpha \rightarrow \beta_1, \dots, \alpha \rightarrow \beta_n$ **zusammen** zu $\alpha \rightarrow (\beta_1 \cup \dots \cup \beta_n)$.

Beispiele: Links/Rechtsreduktion

(1)

$$AB \rightarrow C$$

$$B \rightarrow C$$

(2)

$$A \rightarrow BC$$

$$B \rightarrow C$$

(3)

$$A \rightarrow B$$

$$B \rightarrow C$$

$$A \rightarrow C$$

Zerlegung (Dekomposition) von Relationen

Korrektheitskriterien für die Zerlegung von Relationenschemata:

Verlustlosigkeit

- Die in der ursprünglichen Relationenausprägung Q des Schemas R enthaltenen Informationen müssen aus den Ausprägungen Q_1, \dots, Q_n der neuen Relationenschemata R_1, \dots, R_n rekonstruierbar sein.

Abhängigkeitserhaltung

- Die für R geltenden funktionalen Anhängigkeiten müssen auf die Schemata R_1, \dots, R_n übertragbar sein.

Definition: Projektion

Projektion π (Auswahl von Spalten einer Tabelle):

Sei $A \subseteq sch(R)$. Das Resultat einer Projektion $\pi[A](R)$ ist:

$$sch(\pi[A](R)) = A$$

$$val(\pi[A](R)) = \{t \mid \exists r \in val(R)(t.A = r.A)\}$$

Definition: Natural Join ⋈

Natural Join:

Natürlicher Verbund von Relationen
über gleiche Attributnamen und Attributwerte.

Das Resultat von $R \bowtie S$ mit $A = sch(R)$ und $B = sch(S)$ ist:

$$sch(R \bowtie S) = sch(R) \cup sch(S)$$

$$val(R \bowtie S) = \{ t \mid \exists r \in val(R), s \in val(S): t.A = r.A \wedge t.B = s.B \}$$

$P(X_1, \dots, X_m, Y_1, \dots, Y_k)$

$Q(Y_1, \dots, Y_k, Z_1, \dots, Z_n)$

$P \bowtie Q$

$P - Q$

$P \cap Q$

$Q - P$

X_1	X_2	...	X_m	Y_1	Y_2	...	Y_k	Z_1	Z_2	...	Z_n

Kriterien für die Verlustlosigkeit einer Zerlegung

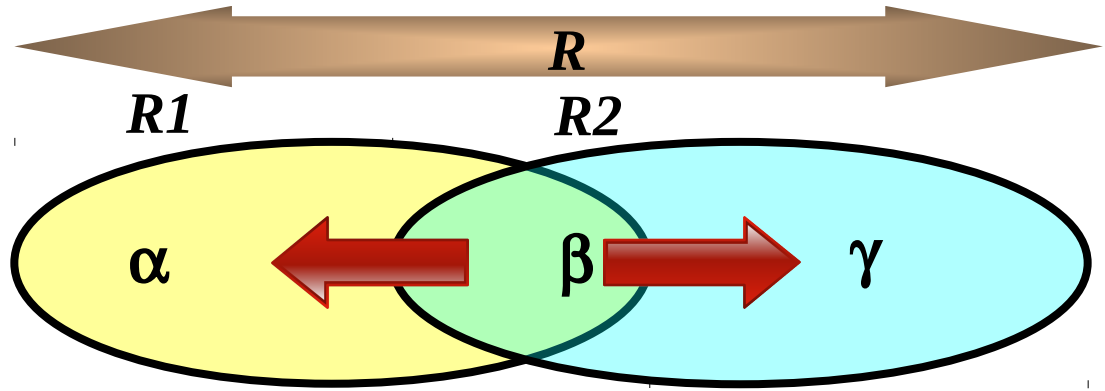
$$\begin{aligned} Rel &:= (R, Q) & R &= R_1 \cup R_2 \\ Rel_1 &:= (R_1, Q_1), & Q_1 &:= \pi[R_1](Rel) \\ Rel_2 &:= (R_2, Q_2), & Q_2 &:= \pi[R_2](Rel) \end{aligned}$$

Die Zerlegung von R in R₁ und R₂ ist verlustlos,
falls für jede mögliche (gültige) Ausprägung Q gilt:

$$R = R_1 \bowtie R_2$$

Hinreichende Bedingung für die Verlustlosigkeit einer Zerlegung

$$\begin{aligned} R_1 \cap R_2 &\rightarrow R_1 \quad \text{oder} \\ R_1 \cap R_2 &\rightarrow R_2 \end{aligned}$$



Biertrinker-Beispiel

<i>Biertrinker</i>		
<i>Lokal</i>	<i>Gast</i>	<i>Bier</i>
Einstein	Gniffke	Pils
Einstein	Anders	Hefeweizen
Mephisto	Gniffke	Hefeweizen

Biertrinker-Beispiel: Verlustige Zerlegung

<i>Biertrinker</i>		
<i>Lokal</i>	<i>Gast</i>	<i>Bier</i>
Einstein	Gniffke	Pils
Einstein	Anders	Hefeweizen
Mephisto	Gniffke	Hefeweizen



<i>Besucht := π [Lokal, Gast] (Biertrinker)</i>	
<i>Lokal</i>	<i>Gast</i>
Einstein	Gniffke
Einstein	Anders
Mephisto	Gniffke

<i>Trinkt := π [Gast, Bier] (Biertrinker)</i>	
<i>Gast</i>	<i>Bier</i>
Gniffke	Pils
Anders	Hefeweizen
Gniffke	Hefeweizen



<i>Besucht ⋈ Trinkt</i>		
<i>Lokal</i>	<i>Gast</i>	<i>Bier</i>
Einstein	Gniffke	Pils
Einstein	Gniffke	Hefeweizen
Einstein	Anders	Hefeweizen
Mephisto	Gniffke	Pils
Mephisto	Gniffke	Hefeweizen

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

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

Wohingegen keine der zwei möglichen, die Verlustlosigkeit garantierenden FDs gelten

- $\{\text{Gast}\} \rightarrow \{\text{Bier}\}$
- $\{\text{Gast}\} \rightarrow \{\text{Kneipe}\}$

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

- (damit sich die Kellner darauf einstellen können?)


Verlustfreie Zerlegung

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



<i>Väter</i> := π [<i>Vater</i> , <i>Kind</i>] (<i>Eltern</i>)	
<i>Vater</i>	<u><i>Kind</i></u>
Johann	Else
Johann	Theo
Heinz	Cleo

<i>Mütter</i> := π [<i>Mutter</i> , <i>Kind</i>] (<i>Eltern</i>)	
<i>Mutter</i>	<u><i>Kind</i></u>
Martha	Else
Maria	Theo



<i>Väter</i> \bowtie <i>Mütter</i>		
<i>Vater</i>	<i>Mutter</i>	<i>Kind</i>
Johann	Martha	Else
Johann	Maria	Theo
Heinz	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 (~Normalform) ist

Abhängigkeitsbewahrung

R ist zerlegt in R_1, \dots, R_n

$$F_R = (F_{R1} \cup \dots \cup F_{Rn}) \quad \text{bzw.} \quad F_R^+ = (F_{R1} \cup \dots \cup F_{Rn})^+$$

Beispiel für Abhängigkeitsverlust:

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



Straßen := π [PLZ, Straße]
(PLZverzeichnis)

<u>PLZ</u>	<u>Straße</u>
15234	Goethestraße
60313	Goethestraße
60437	Galgenstraße

Orte := π [Ort, BLand]
(PLZverzeichnis)

<u>Ort</u>	<u>BLand</u>	<u>PLZ</u>
Frankfurt	Hessen	60313
Frankfurt	Hessen	60437
Frankfurt	Brandenburg	15234

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

Zerlegung der Relation PLZverzeichnis

<i>PLZverzeichnis</i>			
<u>Ort</u>	<u>BLand</u>	<u>Straße</u>	<u>PLZ</u>
Frankfurt	Hessen	Goethestrasse	60313
Frankfurt	Hessen	Galgenstrasse	60437
Frankfurt	Brandenburg	Goethestrasse	15234



Straßen := π [PLZ, Straße] (PLZverzeichnis)

<u>PLZ</u>	<u>Straße</u>
15234	Goethestrasse
60313	Goethestrasse
15235	Goethestrasse
60437	Galgenstrasse

Orte := π [Ort, BLand] (PLZverzeichnis)

<u>Ort</u>	<u>BLand</u>	<u>PLZ</u>
Frankfurt	Hessen	60313
Frankfurt	Hessen	60437
Frankfurt	Brandenburg	15234
Frankfurt	Brandenburg	15235

Zerlegung der Relation PLZverzeichnis

Straßen := π [PLZ, Straße]
(PLZverzeichnis)

<u>PLZ</u>	<u>Straße</u>
15234	Goethestraße
60313	Goethestraße
15235	Goethestraße
60437	Galgenstraße

Orte := π [Ort, BLand]
(PLZverzeichnis)

<u>Ort</u>	<u>BLand</u>	<u>PLZ</u>
Frankfurt	Hessen	60313
Frankfurt	Hessen	60437
Frankfurt	Brandenburg	15234
Frankfurt	Brandenburg	15235

Straßen ⋈ Orte

<u>Ort</u>	<u>BLand</u>	<u>Straße</u>	<u>PLZ</u>
Frankfurt	Hessen	Goethestraße	60313
Frankfurt	Hessen	Galgenstraße	60437
Frankfurt	Brandenburg	Goethestraße	15235
Frankfurt	Brandenburg	Goethestraße	15234

Die FD {Straße, Ort, BLand} → {PLZ} wird verletzt

Normalformen: informeller Überblick

1NF: Das Modell ist strikt relational

2NF: Keine Abhängigkeit von Teilschlüssel

3NF: Keine Kettenabhängigkeiten

BCNF: Keine Abhängigkeit von Teilschlüssel, auch nicht in Kandidatenschlüssel

4NF: Beschreibt mehrwertige Abhängigkeiten

5NF: Relation lässt sich nicht weiter aufspalten, ohne dass Information verloren geht

Erste Normalform

Nur atomare Domänen

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

1NF

<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 (Oracle: Nested Tables)

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

Zweite Normalform (2NF)


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

<i>StudentenBelegung</i>			
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 ist **nicht** in 2NF

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

Zweite Normalform: Beispiel



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?

Lösung: Zerlegung in zwei Relationen

- hören: {[MatrNr, VorlNr]}
- Studenten: {[MatrNr, Name, Semester]}

Beide Relationen sind in 2NF

Dritte Normalform (3NF)

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

- $B \in \alpha$, d.h., die FD ist trivial oder
- Das Attribut B ist ein Schlüsselattribut oder
- α ist Superschlüssel von R

<i>Studenten</i>				
MatrNr	Fachbereich	Standort	Name	Semester
26120	Informatik	Koblenz	Fichte	4
27550	Informatik	Koblenz	Meyer	8
27551	Psychologie	Landau	Carnap	5

Studenten ist **nicht** in 3NF
 $\{\text{Fachbereich}\} \rightarrow \{\text{Standort}\}$

Zerlegung mit dem Synthesealgorithmus

Ziel:

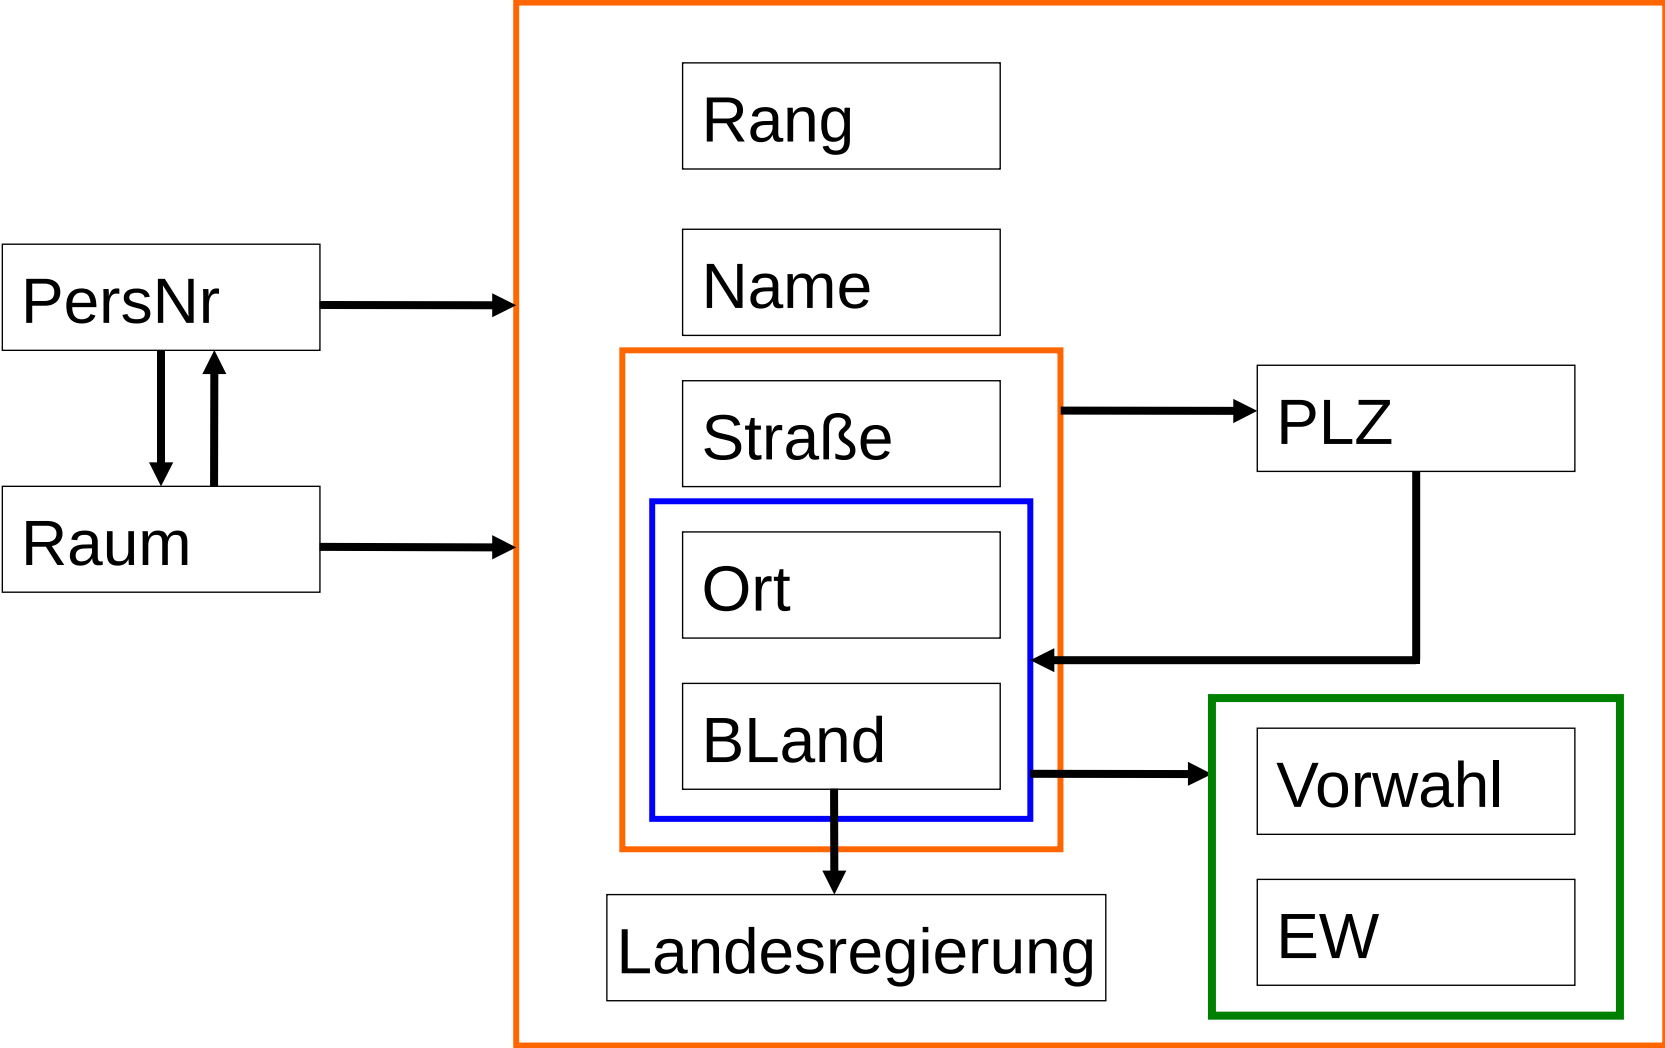
Zerlegung von R mit vorgegebenen FDs F in R_1, \dots, R_n , wobei folgende Kriterien erfüllt sind:

- Zerlegung von R in R_1, \dots, R_n erfolgt verlustlos
- Zerlegung R_1, \dots, R_n ist abhängigkeitsershaltend
- Alle R_1, \dots, R_n sind in 3NF

Synthesealgorithmus

- 1) Bestimme die kanonische Überdeckung F_c zu F . Wiederholung:
 - a. Linksreduktion
 - b. Rechtsreduktion
 - c. Entfernung von FDs der Form $\alpha \rightarrow \emptyset$
 - d. Zusammenfassung gleicher linker Seiten
- 2) Für jede funktionale Abhängigkeit $\alpha \rightarrow \beta \in F_c$:
 - Kreiere ein Relationenschema $R_\alpha := \alpha \cup \beta$
 - Ordne R_α die FDs $F_\alpha := \{\alpha' \rightarrow \beta' \in F_c \mid \alpha' \cup \beta' \subseteq R_\alpha\}$ zu.
- 3) Falls eines der in Schritt 2. erzeugten Schemata einen Kandidatenschlüssel von R bzgl. F_c enthält, sind wir fertig. Sonst wähle einen Kandidatenschlüssel $k \subseteq R$ aus und definiere folgendes Schema:
 - a. $R_k := k$
 - b. $F_k := \emptyset$
- 4) Eliminiere diejenigen Schemata R_α , die in einem anderen Relationenschema $R_{\alpha'}$ enthalten sind, d.h.,
 - $R_\alpha \subseteq R_{\alpha'}$

Anwendung des Synthesearchgorithmus



Anwendung des Synthesealgorithmus

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

1. {PersNr} \rightarrow {Name, Rang, Raum, Ort, Straße, BLand}
2. {Raum} \rightarrow {PersNr}
3. {Straße, BLand, Ort} \rightarrow {PLZ}
4. {Ort, BLand} \rightarrow {EW, Vorwahl}
5. {BLand} \rightarrow {Landesregierung}
6. {PLZ} \rightarrow {BLand, Ort}

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

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

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

Regierungen: {[BLand, Landesregierung]}

2. und 6. fallen weg (Teilrelationen von 1. und 3.)

Gesamtkandidatenschlüssel {PersNr} ist bereits Schlüssel einer Relation

Boyce-Codd-Normalform (BCNF)

BCNF = eine weitere Verschärfung der 3NF

Ein Relationenschema R mit FDs F ist in BCNF, wenn für jede für R geltende funktionale Abhängigkeit der Form $\alpha \rightarrow \beta \in F$ gilt:

- entweder $\beta \subseteq \alpha$, d.h., die Abhängigkeit ist trivial,
- oder α ist ein Superschlüssel von R

Man kann jede Relation **verlustlos** in BCNF-Relationen zerlegen
Manchmal lässt sich dabei die **Abhängigkeitserhaltung** aber **nicht** erzielen

Beispiel: Relation in 3NF, aber nicht in BCNF

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

Geltende FDs:

- {Ort, BLand} → {EW}
- {BLand} → {Ministerpräsident}
- {Ministerpräsident} → {BLand}

Kandidatenschlüssel:

- {Ort, BLand}
- {Ort, Ministerpräsident}

Dekomposition

Man kann grundsätzlich jedes Relationenschema R mit funktionalen Abhängigkeiten F so in R_1, \dots, R_n zerlegen, dass gilt:

- R_1, \dots, R_n ist eine verlustlose Zerlegung von R
- Alle R_1, \dots, R_n sind in BCNF
- Es kann leider nicht immer erreicht werden, dass die Zerlegung R_1, \dots, R_n abhängigkeiterhaltend ist

Dekompositions-Algorithmus

Starte mit $Z = \{R\}$

Solange es noch ein Relationenschema R_i in Z gibt, das nicht in BCNF ist, mache folgendes:

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

Kriterien für die Verlustlosigkeit einer Zerlegung

$$Rel := (R, Q) \quad R = R_1 \cup R_2$$

$$Rel_1 := (R_1, Q_1), \quad Q_1 := \pi[R_1](Rel)$$

$$Rel_2 := (R_2, Q_2), \quad Q_2 := \pi[R_2](Rel)$$


Die Zerlegung von R in R_1 und R_2 ist verlustlos,
falls für jede mögliche (gültige) Ausprägung Q gilt:

$$R = R_1 \bowtie R_2$$

Hinreichende Bedingung für die Verlustlosigkeit einer Zerlegung

$$R_1 \cap R_2 \rightarrow R_1 \quad \text{oder}$$

$$R_1 \cap R_2 \rightarrow R_2$$



Dekomposition der Relation Städte in BCNF-Relationen

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

Geltende FDs:

- {BLand} \rightarrow {Ministerpräsident/in}
- {Ort, BLand} \rightarrow {EW}
- {Ministerpräsident/in} \rightarrow {BLand}

R_{i1} :


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

R_{i2} :

- Städte: {[Ort, BLand, EW]}

Zerlegung ist verlustlos und auch abhängigkeiterhaltend

Dekomposition des PLZverzeichnis in BCNF-Relationen



Funktionale Abhängigkeiten:

- $\{PLZ\} \rightarrow \{Ort, BLand\}$
- $\{Straße, Ort, BLand\} \rightarrow \{PLZ\}$

Betrachte die Zerlegung

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

Diese Zerlegung

- ist verlustlos aber
- Nicht abhängigkeiterhaltend

Zerlegung der Relation PLZverzeichnis

<i>PLZverzeichnis</i>			
<u>Ort</u>	<u>BLand</u>	<u>Straße</u>	<u>PLZ</u>
Frankfurt	Hessen	Goethestrasse	60313
Frankfurt	Hessen	Galgenstrasse	60437
Frankfurt	Brandenburg	Goethestrasse	15234



Straßen := π [PLZ, Straße] (PLZverzeichnis)

<u>PLZ</u>	<u>Straße</u>
15234	Goethestrasse
60313	Goethestrasse
15235	Goethestrasse
60437	Galgenstrasse

Orte := π [Ort, BLand] (PLZverzeichnis)

<u>Ort</u>	<u>BLand</u>	<u>PLZ</u>
Frankfurt	Hessen	60313
Frankfurt	Hessen	60437
Frankfurt	Brandenburg	15234
Frankfurt	Brandenburg	15235

Zerlegung der Relation PLZverzeichnis

Straßen := π [PLZ, Straße]
(PLZverzeichnis)

<u>PLZ</u>	<u>Straße</u>
15234	Goethestrasse
60313	Goethestrasse
15235	Goethestrasse
60437	Galgenstrasse

Orte := π [Ort, BLand]
(PLZverzeichnis)

<u>Ort</u>	<u>BLand</u>	<u>PLZ</u>
Frankfurt	Hessen	60313
Frankfurt	Hessen	60437
Frankfurt	Brandenburg	15234
Frankfurt	Brandenburg	15235

Strassen \bowtie *Orte*

<u>Ort</u>	<u>BLand</u>	<u>Straße</u>	<u>PLZ</u>
Frankfurt	Hessen	Goethestrasse	60313
Frankfurt	Hessen	Galgenstrasse	60437
Frankfurt	Brandenburg	Goethestrasse	15235
Frankfurt	Brandenburg	Goethestrasse	15234

Die FD {Straße, Ort, BLand} \rightarrow {PLZ} wird verletzt

Fragen ?

 kunegis@uni-koblenz.de

 <http://west.uni-koblenz.de/teaching/ws1213/datenbanken>