

Relationale Entwurfstheorie

Relationale Entwurfstheorie

- Ein schlecht entworfenes Schema führt zu folgenden Anomalien
 - Updateanomalien: bei Änderungen *eines* Fakts müssen *viele* Tupel angefaßt werden
 - Einfügeanomalien: beim Einfügen eines Tupels können viele Werte nicht angegeben werden (im schlimmsten Fall sind nicht alle Schlüsselattributwerte bekannt $\Rightarrow$ Tupel kann nicht eingefügt werden)
 - Löschanomalien: beim Löschen eines Tupels geht mehr Information verloren als beabsichtigt

- Ein Finanzberater speichert seine Daten in einem relationalen DBMS
- Es gibt (M)akler, ihre (B)üros, (I)nvestoren, (A)ktien, (D)ividenden und die (Q)uantität einer Aktie, die ein Investor hält
- Alles steht in einer großen Relation:

Finanz(M, B, I, A, D, Q)

Finanz					
M	B	I	A	D	Q
Müller	103	Schmidt	IBM	1.20	50
Müller	103	Schmidt	Merck	1.00	30
Müller	103	Schmidt	Coca Cola	0.00	100
Jung	214	Wilhelm	BASF	0.80	80
Jung	214	Wilhelm	Merck	1.00	140
Jung	214	Wilhelm	IBM	1.20	30
...	...	...	...	...	...

- Was passiert, wenn Müller von 103 nach 145 umzieht?
- Was passiert, wenn Meier als Makler neu anfängt, aber noch keine Kunden betreut?
- Was passiert, wenn Wilhelm alle Aktien verkauft und aussteigt?

- Die Qualität eines relationalen Schemas kann formal überprüft werden
- Auf den ersten Blick enthält die Relation Finanz sehr viel redundante Daten:
 - 103 ist Müllers Büro
 - IBM zahlt eine Dividende von 1.20 auf jede Aktie
 - Der Berater von Wilhelm ist Jung
- Wo kommt diese Redundanz her?
- Bestimmte Attributwerte legen andere Attributwerte fest, es gibt *funktionale Abhängigkeiten*

- Z.B. gibt es eine funktionale Abhängigkeit (kurz FD, für functional dependency) zwischen Makler und Büro: $\text{Makler} \rightarrow \text{Büro}$
- Formale Definition einer FD
 - α und β sind Attributmengen eines relationalen Schemas $\mathcal{R}$
 - Es gibt eine FD $\alpha \rightarrow \beta$, gdw. für *alle* Instanzen von $\mathcal{R}$ gilt: für alle Paare von Tupeln $r, t \in R$ gilt $r.\alpha = t.\alpha \Rightarrow r.\beta = t.\beta$

- Es ist unrealistisch, alle möglichen Instanzen von $\mathcal{R}$ in der Praxis zu prüfen
- FDs müssen aus dem Hintergrundwissen über die Anwendung abgeleitet werden
- Welche anderen FDs gibt es in Finanz?

- $\mathcal{F}_{\mathcal{R}} = \{M \rightarrow B, A \rightarrow D, I \rightarrow M, IA \rightarrow Q\}$
- Was machen wir jetzt mit diesen FDs?
- Man kann einen Schlüssel für $\mathcal{R}$ *berechnen*!

- Eigenschaften eines Schlüssels κ :
 1. $\kappa \subseteq \mathcal{R}$
 2. $\kappa \rightarrow \mathcal{R}$
 3. Es gibt kein $\kappa' \subset \kappa$ so daß $\kappa' \rightarrow \mathcal{R}$
- Eigenschaft 2. wird Vollständigkeit genannt, Eigenschaft 3. Minimalität
- κ wird auch *Kandidatenschlüssel* genannt (es kann mehr als ein κ geben, das obige Eigenschaften erfüllt)
- Ein κ wird als *Primärschlüssel* gewählt
- Wenn nur Eigenschaften 1. und 2. gelten, wird κ *Superschlüssel* genannt

- Ist IA ein Schlüssel von Finanz?
- Eigenschaft 1: ✓
- Für die Überprüfung von 2. und 3. brauchen wir weitere Konzepte der Relationentheorie

- Aus einer Menge $\mathcal{F}$ von FDs sind weitere FDs herleitbar
- $\mathcal{F}^+$, die Menge aller aus $\mathcal{F}$ herleitbaren FDs, wird Hülle (closure) von $\mathcal{F}$ genannt
- Es gibt Inferenzregeln, die *Armstrong Axiome*, zum Herleiten weiterer FDs

- α, β und γ sind Teilmengen von $\mathcal{R}$
- Dann gibt es folgende korrekte und vollständige Regeln:
 - Reflexivität: $\beta \subseteq \alpha \Rightarrow \alpha \rightarrow \beta$
 - Verstärkung: Falls $\alpha \rightarrow \beta$, dann gilt auch $\alpha\gamma \rightarrow \beta\gamma$ ($\alpha\gamma$ steht für $\alpha \cup \gamma$)
 - Transitivität: $\alpha \rightarrow \beta$ und $\beta \rightarrow \gamma \Rightarrow \alpha \rightarrow \gamma$
- Mit Hilfe der Armstrong Axiome können alle gültigen FDs hergeleitet werden.

- Die folgenden Zusatzregeln sind eigentlich nicht erforderlich, aber häufig nützlich:
 - Vereinigungsregel: Wenn $\alpha \rightarrow \beta$ und $\alpha \rightarrow \gamma$, dann gilt auch $\alpha \rightarrow \beta\gamma$
 - Dekompositionsregel: Wenn $\alpha \rightarrow \beta\gamma$, dann gelten auch $\alpha \rightarrow \beta$ und $\alpha \rightarrow \gamma$
 - Pseudotransitivitätsregel: Wenn $\alpha \rightarrow \beta$ und $\gamma\beta \rightarrow \delta$, dann gilt auch $\alpha\gamma \rightarrow \delta$
- Da die Anwendung der Armstrong Axiome für die Schlüsselfindung etwas aufwendig ist, benutzt man meistens Attributhüllen.

- Die *Attributhülle* $AH(\alpha)$ einer Attributmenge α ist die Menge alle Attribute aus $\mathcal{R}$ die funktional von α abhängen
- Es gibt einen einfachen Algorithmus zur Bestimmung von $AH(\alpha)$:

```
AH :=  $\alpha$ 
while (AH ändert sich noch) do
  for each FD  $\beta \rightarrow \gamma$  in  $\mathcal{F}_{\mathcal{R}}$  do
    if ( $\beta \subseteq AH$ )
      then  $AH := AH \cup \gamma$ 
```

- $AH(IA) = MBIAQD$
 $\Rightarrow IA$ ist Superschlüssel
- $AH(I) = IMB$
 $AH(A) = AD$
 $\Rightarrow IA$ ist auch Schlüssel

- Es gibt *Normalformen* (NF) die etwas über die Qualität eines Schemas aussagen
- Wir betrachten 1NF, 2NF, 3NF, BCNF, 4NF
- Es gibt noch höhere, die aber mehr von theoretischem Interesse sind

- Ein relationales Schema ist in 1NF, gdw. alle Attribute nur atomare Werte annehmen

In 1NF:

Nicht in 1NF:

Eltern		
Mutter	Vater	Kinder
Marie	Hans	{Ines, David}
...	...	...

Eltern		
Mutter	Vater	Kind
Marie	Hans	Ines
Marie	Hans	David
...	...	...

- Ein Relationenschema ist in 2NF, gdw. es in 1NF ist und jedes Nichtschlüsselattribut (NSA) voll funktional von jedem Schlüssel abhängt
- β hängt voll funktional von α ab ($\alpha \xrightarrow{\bullet} \beta$), gdw. $\alpha \rightarrow \beta$ und es existiert kein $\alpha' \subset \alpha$, so daß $\alpha' \rightarrow \beta$
- Finanz z.B. ist nicht in 2NF, da IA Schlüssel, aber $I \rightarrow M$
- Verstoß gegen 2NF deutet darauf hin, daß verschiedene Beziehungen (zwischen Entitäten) in einer Relation gemischt wurden

- Selbst bei Erfüllung von 2NF können immer noch Redundanzen im Schema enthalten sein (durch transitive Abhängigkeiten)
- Ein Relationenschema ist in 3NF, gdw. für jede FD $\alpha \rightarrow \beta$ mindestens eine der folgenden Eigenschaften gilt:
 - $\alpha \rightarrow \beta$ ist trivial, d.h., $\beta \subseteq \alpha$
 - α ist ein Superschlüssel
 - Jedes Attribut in β ist in einem Schlüssel enthalten
- Auf diese Weise werden transitive Abhängigkeiten vermieden (in denen NSAe über andere NSAe vom Schlüssel abhängen)

- Weitere Verschärfung ist BCNF, hier dürfen alle Attribute nur noch direkt vom Schlüssel abhängen
- Ein Relationenschema ist in BCNF, gdw. für jede FD $\alpha \rightarrow \beta$ mindestens eine der folgenden Eigenschaften gilt:
 - $\alpha \rightarrow \beta$ ist trivial, d.h., $\beta \subseteq \alpha$
 - α ist ein Superschlüssel
- Für weitere Beschreibungen von Redundanzen müssen wir über FDs hinausgehen

Fähigkeiten		
PersNr	Sprache	ProgSprache
3002	Englisch	C
3002	Deutsch	C
3002	Englisch	Java
3002	Deutsch	Java
3005	Englisch	C
3005	Deutsch	C

- In diesem Schema gibt es keine FDs, trotzdem haben wir Redundanz

- Jemand der fünf Programmiersprachen und vier Sprachen beherrscht, benötigt 20 Tupel zur Speicherung dieser Information!
- Hier werden voneinander unabhängige Konzepte miteinander vermischt
- Kompaktere Speicherung möglich:

Fähigkeiten	
PersNr	Sprache
3002	Englisch
3002	Deutsch
3005	Englisch
3005	Deutsch

Fähigkeiten	
PersNr	ProgSprache
3002	C
3002	Java
3005	C

- Es gibt *mehrwertige Abhängigkeiten* (MVDs: multivalued dependencies) in diesem Schema:
PersNr $\twoheadrightarrow$ Sprache und PersNr $\twoheadrightarrow$ ProgSprache
- Formale Definition: $\alpha, \beta, \gamma \subseteq \mathcal{R}$ (mit $\alpha \cup \beta \cup \gamma = \mathcal{R}$);
 $\alpha \twoheadrightarrow \beta$ gilt, gdw. für jede Instanz R gilt: für jedes Paar von Tupeln t_1, t_2 in R mit $t_1.\alpha = t_2.\alpha$ existiert ein $t_3 \in R$ mit $t_3.\alpha = t_1.\alpha$, $t_3.\beta = t_1.\beta$ und $t_3.\gamma = t_2.\gamma$
- Umgangssprachlich bedeutet dies, daß für alle Tupel mit gleichem Wert für α alle β, γ -Kombinationen vorkommen

- MVDs sind eine Verallgemeinerung von FDs, d.h. jede FD ist eine MVD (aber nicht unbedingt umgekehrt)
- Ähnlich den Armstrong Axiomen gibt es auch für MVDs Herleitungsregeln (sollen hier aber nicht im Detail besprochen werden)
- Eine wichtige Eigenschaft von MVDs soll genannt werden: $\alpha \twoheadrightarrow \beta \Rightarrow \alpha \twoheadrightarrow \gamma$ für $\gamma = \mathcal{R} - \alpha - \beta$

- In der vierten Normalform (4NF) werden die Eigenschaften der BCNF auf MVDs ausgeweitet
- Ein Relationenschema ist in 4NF, gdw. für jede MVD $\alpha \twoheadrightarrow \beta$ mindestens eine der folgenden Eigenschaften gilt:
 - $\alpha \twoheadrightarrow \beta$ ist trivial, d.h., $\beta \subseteq \alpha$ **ODER** $\alpha \cup \beta = \mathcal{R}$
 - α ist ein Superschlüssel

- Eine höhere NF schließt alle niedrigeren mit ein:
 $4NF \subset BCNF \subset 3NF \subset 2NF \subset 1NF$
- Je höher die NF, desto besser das Schema, d.h. desto weniger Redundanzen
- Was macht man, wenn die Qualität des momentanen Schemas nicht gut genug ist?
- Man überführt Schema in eine höhere Normalform und zwar mit Hilfe von Zerlegungen


- Ein Schema $\mathcal{R}$ wird in die Teilschemata $\mathcal{R}_1, \dots, \mathcal{R}_n$ zerlegt, mit $\mathcal{R}_i \subset \mathcal{R}$ für $1 \leq i \leq n$
- Eine Zerlegung sollte zwei Eigenschaften haben:
 - Verlustlosigkeit: die in der ursprünglichen Instanz R enthaltene Information muß aus den Instanzen $R_1, \dots, R_n$ rekonstruierbar sein (für alle möglichen Instanzen R)
 - Abhängigkeitsbewahrung: alle FDs in $\mathcal{F}_{\mathcal{R}}$ sollten in den $\mathcal{F}_{\mathcal{R}_1}, \dots, \mathcal{F}_{\mathcal{R}_n}$ bewahrt bleiben

- Zerlegung von $\mathcal{R}$ in $\mathcal{R}_1$ und $\mathcal{R}_2$ (mit $\mathcal{R} = \mathcal{R}_1 \cup \mathcal{R}_2$ und $R_1 = \pi_{\mathcal{R}_1}(R)$, $R_2 = \pi_{\mathcal{R}_2}(R)$)
- Die Zerlegung ist verlustlos, wenn für jede mögliche Instanz R von $\mathcal{R}$ gilt:

$$R = R_1 \bowtie R_2$$

- Hinreichende Bedingung für verlustlose Zerlegung:
 - $(\mathcal{R}_1 \cap \mathcal{R}_2) \rightarrow \mathcal{R}_1 \in \mathcal{F}_{\mathcal{R}}^+$ oder
 - $(\mathcal{R}_1 \cap \mathcal{R}_2) \rightarrow \mathcal{R}_2 \in \mathcal{F}_{\mathcal{R}}^+$

Finanz					
M	B	I	A	D	Q
Müller	103	Schmidt	IBM	1.20	50
Müller	103	Schmidt	Merck	1.00	30
Jung	214	Wilhelm	Merck	1.00	140
Jung	214	Wilhelm	IBM	1.20	30



Finanz1			Finanz2			
M	B	A	I	A	D	Q
Müller	103	IBM	Schmidt	IBM	1.20	50
Müller	103	Merck	Schmidt	Merck	1.00	30
Jung	214	Merck	Wilhelm	Merck	1.00	140
Jung	214	IBM	Wilhelm	IBM	1.20	30

Finanz1 ⋈ Finanz2

Finanz					
M	B	I	A	D	Q
Müller	103	Schmidt	IBM	1.20	50
Müller	103	Schmidt	Merck	1.00	30
Jung	214	Wilhelm	Merck	1.00	140
Jung	214	Wilhelm	IBM	1.20	30
Müller	103	Wilhelm	IBM	1.20	50
Müller	103	Wilhelm	Merck	1.00	30
Jung	214	Schmidt	Merck	1.00	140
Jung	214	Schmidt	IBM	1.20	30

- Zerlegung von $\mathcal{R}$ in $\mathcal{R}_1, \dots, \mathcal{R}_n$
- Zerlegung ist abhängigkeitsbewahrend, wenn
$$\mathcal{F}_{\mathcal{R}} \equiv \left(\mathcal{F}_{\mathcal{R}_1} \cup \dots \cup \mathcal{F}_{\mathcal{R}_{rmn}} \right) \quad \text{bzw.}$$
$$\mathcal{F}_{\mathcal{R}}^+ = \left(\mathcal{F}_{\mathcal{R}_1} \cup \dots \cup \mathcal{F}_{\mathcal{R}_n} \right)^+$$
- Im vorherigen Beispiel geht die FD $I \rightarrow M$ verloren, ist also auch nicht abhängigkeitsbewahrend

- Zerlegung wird normalerweise nicht jedes Mal mühsam per Hand gemacht und überprüft
- Wichtigster Algorithmus: 3NF-Synthesealgorithmus
 - Zerlegt ein Schema verlustlos und abhängigkeitsbewahrend in 3NF
 - Braucht als Eingabe allerdings eine redundanzfreie Menge von FDs (kanonische Überdeckung)

- $\mathcal{F}_c$ heisst kanonische Überdeckung von $\mathcal{F}$, wenn die folgenden drei Kriterien erfüllt sind:
 - $\mathcal{F}_c \equiv \mathcal{F}$, d.h. $\mathcal{F}_c^+ = \mathcal{F}^+$
 - In $\mathcal{F}_c$ existieren keine FDs $\alpha \rightarrow \beta$, bei denen α oder β überflüssige Attribute enthalten.
 - Jede linke Seite einer FD in $\mathcal{F}_c$ ist einzigartig. Dies kann durch sukzessive Anwendung der Vereinigungsregel erzielt werden:
 $\alpha \rightarrow \beta, \alpha \rightarrow \gamma \Rightarrow \alpha \rightarrow \beta\gamma$

- Wann gibt es keine überflüssigen Attribute?
 - $\forall A \in \alpha :$
 $(\mathcal{F}_c - (\alpha \rightarrow \beta) \cup ((\alpha - A) \rightarrow \beta)) \not\equiv \mathcal{F}_c$
 - $\forall B \in \beta :$
 $(\mathcal{F}_c - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B))) \not\equiv \mathcal{F}_c$
- Man kann überflüssige Attribute durch Links- bzw. Rechtsreduktion entfernen

- Führe für jede FD $\alpha \rightarrow \beta \in \mathcal{F}$ die Linksreduktion durch
- Überprüfe für alle $A \in \alpha$, ob A überflüssig ist, d.h. ob $\beta \subseteq AttrH\ddot{u}lle(\mathcal{F}, \alpha - A)$
- Falls ja, ersetze $\alpha \rightarrow \beta$ durch $(\alpha - A) \rightarrow \beta$.

- Führe für jede (verbliebene) FD $\alpha \rightarrow \beta$ die Rechtsreduktion durch
- Überprüfe für alle $B \in \beta$, ob $B \in AttrHülle(\mathcal{F} - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B)), \alpha)$
- Falls ja, ist B auf der rechten Seite überflüssig und kann eliminiert werden, d.h. $\alpha \rightarrow \beta$ wird durch $\alpha \rightarrow (\beta - B)$ ersetzt.

- Entferne die FDs der Form $\alpha \rightarrow \emptyset$, die im zweiten Schritt möglicherweise entstanden sind.
- Fasse mittels der Vereinigungsregel FDs der Form $\alpha \rightarrow \beta_1, \dots, \alpha \rightarrow \beta_n$ zusammen, so dass $\alpha \rightarrow \beta_1 \cup \dots \cup \beta_n$ verbleibt.
- Damit ist kanonische Überdeckung berechnet
- Je nach Abarbeitungsreihenfolge der FDs können verschiedene Überdeckungen entstehen (die aber alle redundanzfrei sind)

- Erster Schritt: für jede FD $\alpha \rightarrow \beta$ in $\mathcal{F}_c$ forme ein Unterschema $\mathcal{R}_\alpha = \alpha \cup \beta$, ordne $\mathcal{R}_\alpha$ die FDs $\mathcal{F}_\alpha := \{\alpha' \rightarrow \beta' \in \mathcal{F}_c \mid \alpha' \cup \beta' \subseteq \mathcal{R}_\alpha\}$ zu
- Zweiter Schritt: Füge ein Schema $\mathcal{R}_\kappa$ mit einem Kandidatenschlüssel hinzu
- Dritter Schritt: eliminiere redundante Schemata, d.h. falls $\mathcal{R}_i \subseteq \mathcal{R}_j$, verwirfe $\mathcal{R}_i$

- Anwendung des 3NF-Synthesealgorithmus auf Finanz mit $\mathcal{F}_{\mathcal{R}_c} = \{M \rightarrow B, A \rightarrow D, I \rightarrow M, IA \rightarrow Q\}$
- Ergebnis:
 - $\mathcal{R}_M(M, B)$
 - $\mathcal{R}_I(I, M)$
 - $\mathcal{R}_A(A, D)$
 - $\mathcal{R}_{IA}(I, A, Q)$
- Was ist mit den Anomalien vom Anfang des Kapitels passiert? Sie sind verschwunden!

- Es gibt noch weitere Zerlegungsalgorithmen für BCNF und 4NF
- Problem: es gibt Schemata, die nicht abhängigkeitsbewahrend in BCNF oder 4NF zerlegt werden können
- Meistens gibt man sich mit 3NF zufrieden, weiterer Grund: höhere Normalformen bevorzugen Updateoperationen vor Anfrageoperationen

- Starte mit $Z = \{\mathcal{R}\}$
- Solange es noch ein $\mathcal{R}_i \in Z$ gibt, das nicht in BCNF ist:
 - Finde eine FD $(\alpha \rightarrow \beta) \in F^+$ mit
 - $\alpha \cup \beta \subseteq \mathcal{R}_i$
 - $\alpha \cap \beta = \emptyset$
 - $\alpha \rightarrow \mathcal{R}_i \notin F^+$
 - Zerlege $\mathcal{R}_i$ in $\mathcal{R}_{i_1} := \alpha \cup \beta$ und $\mathcal{R}_{i_2} := \mathcal{R}_i - \beta$
 - Entferne $\mathcal{R}_i$ aus Z und füge $\mathcal{R}_{i_1}$ und $\mathcal{R}_{i_2}$ ein, also $Z := (Z - \{\mathcal{R}_i\}) \cup \{\mathcal{R}_{i_1}\} \cup \{\mathcal{R}_{i_2}\}$

- Starte mit $Z = \{\mathcal{R}\}$
- Solange es noch ein $\mathcal{R}_i \in Z$ gibt, das nicht in 4NF ist:
 - Finde eine MVD $\alpha \twoheadrightarrow \beta \in \mathcal{F}^+$ mit
 - $\alpha \cup \beta \subset \mathcal{R}_i$
 - $\alpha \cap \beta = \emptyset$
 - $\alpha \rightarrow \mathcal{R}_i \notin \mathcal{F}^+$
 - Zerlege $\mathcal{R}_i$ in $\mathcal{R}_{i_1} := \alpha \cup \beta$ und $\mathcal{R}_{i_2} := \mathcal{R}_i - \beta$
 - Entferne $\mathcal{R}_i$ aus Z und füge $\mathcal{R}_{i_1}$ und $\mathcal{R}_{i_2}$ ein, also $Z := (Z - \{\mathcal{R}_i\}) \cup \{\mathcal{R}_{i_1}\} \cup \{\mathcal{R}_{i_2}\}$

- Mit Hilfe von Normalformen kann die Qualität eines Schemas bestimmt werden
- Die Verlustlosigkeit ist für alle Zerlegungsalgorithmen garantiert
- Die Abhängigkeitsbewahrung kann nur bei den Zerlegungen bis zur dritten Normalform garantiert werden