



Thomas Studer
Relationale Datenbanken:
Von den theoretischen Grundlagen
zu Anwendungen mit PostgreSQL
Springer, 2016
ISBN 978-3-662-46570-7

Dieser Foliensatz darf frei verwendet werden unter der Bedingung, dass diese Titelfolie nicht entfernt wird.

Datenbanken



Das Relationenmodell

Thomas Studer

Institut für Informatik
Universität Bern

Relationen und Tabellen

Betrachte die 2-stellige Relation

$$\text{Autos} := \{(\text{Opel}, \text{silber}), (\text{VW}, \text{rot}), (\text{Audi}, \text{schwarz})\} .$$

Wir können diese Relation als Tabelle mit zwei Spalten darstellen:

Opel	silber
VW	rot
Audi	schwarz

Attribute und Domänen

Wir geben jeder Spalte der Tabellendarstellung einer Relation einen Namen. Diese Namen heissen *Attribute*.

In der Tabellenform geben wir den Namen der Relation und die Attribute als Überschriften folgendermassen an:

Autos	
Marke	Farbe
Opel	silber
VW	rot
Audi	schwarz

Die Menge von möglichen Werten, die ein Attribut annehmen kann, bezeichnen wir als die *Domäne* dieses Attributs.

Null-Werte

Es kann vorkommen, dass der Wert eines Attributes unbekannt ist. Dies kann sein, weil wir den Wert des Attributs nicht kennen oder weil es noch keinen Wert besitzt.

Nehmen wir an, die Relation Autos hat noch ein drittes Attribut Fahrer. Es kann sein, dass wir den Fahrer eines Autos nicht kennen oder dass es noch keinen Fahrer hat. Um diese Fälle zu modellieren, führen wir einen speziellen Wert Null ein, *welcher zu jeder Domäne gehört*.

In der Tabellenform schreiben wir häufig – anstelle von Null.

Autos		
Marke	Farbe	Fahrer
Opel	silber	Tom
VW	rot	-
Audi	schwarz	Eva

Semantik von Null

Da wir Null verwenden, um auszudrücken, dass der Wert eines Attributs unbekannt ist, erhält Null eine spezielle Semantik bezüglich der Gleichheit:

Es gilt *nicht*, dass $\text{Null} = \text{Null}$. (1)

Wenn wir zwei unbekannte Werte vergleichen, so wissen wir eben nicht, ob sie gleich sind. Deshalb verwenden wir eine Semantik für die (1) der Fall ist.

Schwache Gleichheitsrelation

An einigen Stellen werden wir zwei `Null` Werte als gleichwertig betrachten müssen. Dazu führen wir folgende schwache Gleichheitsrelation zwischen zwei atomaren Objekten a und b ein:

$$a \simeq b \quad \text{g.d.w.} \quad a = b \quad \text{oder} \quad (a \text{ ist Null und } b \text{ ist Null}).$$

Für zwei n -Tupel definieren wir analog:

$$(a_1, \dots, a_n) \simeq (b_1, \dots, b_n) \quad \text{g.d.w.} \quad a_i \simeq b_i \quad \text{für alle } 1 \leq i \leq n.$$

Relation und n -Tupel über Domänen D_1, \dots, D_n

Gegeben seien n Domänen D_1, \dots, D_n . Ein n -Tupel über D_1, \dots, D_n ist ein Objekt der Form

$$(a_1, \dots, a_n),$$

wobei $a_i \in D_i$ für alle $1 \leq i \leq n$. Eine n -stellige *Relation* R über den Domänen D_1, \dots, D_n ist eine Menge von n -Tupeln über D_1, \dots, D_n . Das heißt

$$R \subseteq \{(x_1, \dots, x_n) \mid x_1 \in D_1 \text{ und } \dots \text{ und } x_n \in D_n\} .$$

Relationenschema

Relationenschemata (oder einfach nur *Schemata*) spezifizieren die bei Relationen verwendeten Attribute und Domänen. Es handelt sich dabei um Sequenzen der Form

$$(A_1 : D_1, \dots, A_n : D_n) ,$$

wobei A_1, \dots, A_n Attribute mit den jeweiligen Domänen D_1, \dots, D_n sind. Ergeben sich die Domänen unmittelbar aus dem Kontext oder sind sie unwichtig, so schreiben wir manchmal nur

$$(A_1, \dots, A_n)$$

anstelle von $(A_1 : D_1, \dots, A_n : D_n)$. Weiter verwenden wir die Sprechweise *R ist eine Relation über A_1, \dots, A_n* und meinen damit, dass R eine Relation über den dazugehörigen Domänen D_1, \dots, D_n ist. Dafür sagen wir auch *R ist eine Instanz des Schemas (A_1, \dots, A_n)* .

Relationales Datenbank-Schema

Als *relationales Datenbank-Schema* (oder kurz *DB-Schema*) bezeichnen wir die Menge aller verwendeten Relationenschemata.

Relationale Datenbank

Als *relationale Datenbank* (oder kurz *relationale DB*) bezeichnen wir das verwendete relationale Datenbank-Schema zusammen mit den momentanen Werten der Relationen.

Eine relationale Datenbank besteht somit aus einem DB-Schema zusammen mit den aktuellen Instanzen aller Schemata des DB-Schemas. Wir sprechen in diesem Zusammenhang auch von einer *Instanz* eines DB-Schemas und meinen damit die Menge der aktuellen Instanzen aller Schemata des DB-Schemas.

Schlüssel

Es seien A_1, \dots, A_n Attribute,

$$\mathcal{S} = (A_1, \dots, A_n)$$

ein Relationenschema und R eine Instanz von \mathcal{S} .

- 1 Ist t ein n -Tupel, das zu R gehört, so schreiben wir $t[A_i]$ für den Wert von t bei Attribut A_i . Für $(a_1, \dots, a_i, \dots, a_n) \in R$ heisst das

$$(a_1, \dots, a_i, \dots, a_n)[A_i] = a_i \ .$$

- 2 Ist $K = (A_{i_1}, \dots, A_{i_m})$ eine Sequenz von Attributen, so definieren wir für ein n -Tupel $(a_1, \dots, a_i, \dots, a_n) \in R$

$$(a_1, \dots, a_i, \dots, a_n)[K] := (a_{i_1}, \dots, a_{i_m}) \ . \quad (2)$$

Für $s, t \in R$ bedeutet also $s[K] = t[K]$, dass die Werte von s und t in allen Attributen aus K übereinstimmen.

Beispiel

Betrachten wir die Relation

Autos

Marke	Farbe	Baujahr	Vorname	Nachname
Opel	silber	2010	Tom	Studer
Opel	schwarz	2010	Eva	Studer
VW	rot	2014	Eva	Studer
Audi	schwarz	2014	Eva	Meier

Es sei nun

$$t := (\text{Opel}, \text{schwarz}, 2010, \text{Eva}, \text{Studer}) .$$

Damit gilt

$$t[(\text{Marke}, \text{Farbe})] = (\text{Opel}, \text{schwarz})$$

und

$$t[(\text{Nachname}, \text{Baujahr})] = (\text{Studer}, 2010) .$$

Schlüssel 2

Frage: Wie können wir in einer Instanz R von \mathcal{S} die einzelnen Elemente unterscheiden?

Dazu wählen wir einen sogenannten *Primärschlüssel*. Dies ist eine Sequenz von Attributen

$$K = (A_{i_1}, \dots, A_{i_m}) .$$

Dann verlangen wir für alle Instanzen R von \mathcal{S} und alle $s, t \in R$, dass

$$s[K] = t[K] \implies s \simeq t .$$

Wir geben den Primärschlüssel an, indem wir beim Relationenschema diejenigen Attribute unterstreichen, welche zum gewählten Primärschlüssel gehören.

Beispiel Primärschlüssel

Betrachten wir die Relation

Autos

Marke	Farbe	Baujahr	Vorname	Nachname
Opel	silber	2010	Tom	Studer
Opel	schwarz	2010	Eva	Studer
VW	rot	2014	Eva	Studer
Audi	schwarz	2014	Eva	Meier

Es sind bspw. die beiden folgenden Primärschlüssel möglich:

(Marke, Farbe) und (Baujahr, Vorname, Nachname) . (3)

Falls wir (Marke, Farbe) als Primärschlüssel wählen, so geben wir das Schema wie folgt an:

(Marke, Farbe, Baujahr, Vorname, Nachname) .

Sprechende Schlüssel

In einer echten Datenbankanwendung sind beide möglichen Primärschlüssel aus (3) ungeeignet.

In der Praxis wird ein zusätzliches Attribut, nennen wir es `Auto_Id`, hinzugefügt, welches als Primärschlüssel dient. Dieses Attribut hat nur den Zweck, die verschiedenen Elemente der Relation eindeutig zu bestimmen. Es beschreibt aber keine echte Eigenschaft von Autos. Wir nennen einen solchen Primärschlüssel einen *nicht-sprechenden* Schlüssel.

Ein *sprechender* Schlüssel hingegen hat eine logische Beziehung zu einem oder mehreren Attributen des Schemas.

Sprechende Schlüssel

Es ist gute Praxis *keine* sprechenden Schlüssel zu verwenden, da diese die Tendenz haben zu zerbrechen. Beispiele dazu sind:

- ① das System der AHV-Nummern (eindeutige Personennummer der Alters- und Hinterlassenenversicherung) in der Schweiz, welches 2008 geändert wurde,
- ② die Internationale Standardbuchnummer (ISBN), für die 2005 ein revidierter Standard eingeführt wurde.

Probleme

Autos

Marke	Farbe	Baujahr	Vorname	Nachname
Opel	silber	2010	Tom	Studer
Opel	schwarz	2010	Eva	Studer
VW	rot	2014	Eva	Studer
Audi	schwarz	2014	Eva	Meier

In dieser Tabelle sind die Daten zu Eva Studer doppelt abgespeichert.

Gefahr von Inkonsistenzen

Besser: zwei Tabellen

Autos

<u>Marke</u>	<u>Farbe</u>	Baujahr	FahrerId
Opel	silber	2010	1
Opel	schwarz	2010	2
VW	rot	2014	2
Audi	schwarz	2014	3

Personen

<u>PersId</u>	Vorname	Nachname
1	Tom	Studer
2	Eva	Studer
3	Eva	Meier

FahrerId *referenziert* die Tabelle Personen

FahrerId ist ein *Fremdschlüssel* für Personen

Integritätsbedingungen

Unter *Integritätsbedingungen* (oder *Constraints*) werden Zusicherungen verstanden, welche die in der Datenbank enthaltenen Daten betreffen.

Wir unterscheiden

- 1 *Strukturelle Regeln* (statische Integritätsbedingungen), die in einem Zustand erfüllt sein müssen, damit er erlaubt ist.
- 2 *Verhaltensregeln* (dynamische Integritätsbedingungen), die bei der Ausführung von Änderungen erfüllt sein müssen.

Unique Constraints

Ein *unique Constraint* auf einem DB-Schema

$$\mathcal{S} = (A_1, \dots, A_n)$$

ist bestimmt durch eine Sequenz von Attributen

$$U = (A_{i_1}, \dots, A_{i_m}) .$$

Definition (Integritätsregel 1)

Gegeben sei ein Relationenschema \mathcal{S} mit einem unique Constraint U . Für jede Instanz R von \mathcal{S} und alle $s, t \in R$ muss gelten

$$s[U] = t[U] \implies s \simeq t .$$

Beispiel

Sei $\mathcal{S} := (\text{Marke}, \text{Farbe}, \text{Baujahr})$

mit einem unique Constraint $U := (\text{Marke}, \text{Farbe})$.

Die folgende Instanz Autos von \mathcal{S} erfüllt den unique Constraint U :

Autos		
Marke	Farbe	Baujahr
Opel	silber	2010
Null	schwarz	2012
Null	schwarz	2014

In der Tat ist es *nicht* der Fall, dass

$$(\text{Null}, \text{schwarz}) = (\text{Null}, \text{schwarz}) ,$$

da $\text{Null} = \text{Null}$ nicht gilt. Somit ist die Integritätsregel 1 erfüllt, obwohl die beiden Einträge mit $(\text{Null}, \text{schwarz})$ unterschiedliche Werte für das Attribut Baujahr haben.

Not null Constraints

Ein *not null Constraint* auf einem gegebenen DB-Schema $\mathcal{S} = (A_1, \dots, A_n)$ ist bestimmt durch ein Attribut A_i .

Definition (Integritätsregel 2)

Gegeben sei ein Relationenschema \mathcal{S} mit einem not null Constraint A_i . Für jede Instanz R von \mathcal{S} und alle $s \in R$ muss gelten

$s[A_i]$ hat nicht den Wert Null.

Primary key Constraints

Definition (Integritätsregel 3)

Gegeben sei ein Relationenschema \mathcal{S} mit einem Primärschlüssel K . Für jede Instanz R von \mathcal{S} und alle $s, t \in R$ muss gelten

$$s[K] = t[K] \implies s \simeq t .$$

Zusätzlich muss für jedes Attribute A_i , welches in K vorkommt, gelten:
Für jede Instanz R von \mathcal{S} und alle $s \in R$

$$s[A_i] \text{ hat nicht den Wert Null.}$$

References Constraints

Es seien zwei Schemata $\mathcal{S}_1 = (A_1, \dots, A_n)$ und $\mathcal{S}_2 = (B_1, \dots, B_h)$ gegeben. Zusätzlich sei auf \mathcal{S}_2 ein unique Constraint $U := (B_{j_1}, \dots, B_{j_m})$ definiert worden. Ein *references Constraint* von \mathcal{S}_1 nach U ist bestimmt durch eine Sequenz

$$F := (A_{i_1}, \dots, A_{i_m})$$

von Attributen aus \mathcal{S}_1 , welche dieselbe Länge hat wie U . Wir sagen dann F *referenziert* U .

Definition (Integritätsregel 4)

Gegeben seien ein Relationenschema \mathcal{S}_2 mit einem unique Constraint U sowie ein Relationenschema \mathcal{S}_1 mit einem references Constraint $F = (A_{i_1}, \dots, A_{i_m})$ nach U . Für jede Instanz R von \mathcal{S}_1 und jede Instanz S von \mathcal{S}_2 muss gelten: Für jedes $t \in R$, falls

$$t[A_{i_k}] \text{ ist nicht Null für alle } 1 \leq k \leq m,$$

dann gibt es $s \in S$ mit

$$t[F] = s[U] .$$

References Constraints 2

Da jeder primary key Constraint einen unique Constraint impliziert, können wir anstelle von U auch den Primärschlüssel von S_2 verwenden. Da ein Schema nur einen Primärschlüssel besitzen kann, brauchen wir diesen nicht explizit anzugeben. Wir sagen dann F referenziert das Schema S_2 oder eben F ist ein Fremdschlüssel (foreign key) für S_2 .

References Constraints 3

Autos

<u>Marke</u>	<u>Farbe</u>	Baujahr	FahrerId
Opel	silber	2010	1
Opel	schwarz	2010	2
VW	rot	2014	2
VW	blau	2015	-

Personen

<u>PersId</u>	Vorname	Nachname
1	Tom	Studer
2	Eva	Studer

Postulat

Das Einhalten der vier Integritätsregeln sollte von einem Datenbanksystem laufend automatisch überprüft werden.