LMU LUDWIG-MAXIMILIANS-UNIVERSITY MUNICH
DEPARTMENT INSTITUTE FOR INFORMATICS
DATABASE SYSTEMS GROUP

Skript zur Vorlesung:

Einführung in die Informatik: Systeme und Anwendungen

Sommersemester 2016

Kapitel 3: Datenbanksysteme

Vorlesung: Prof. Dr. Christian Böhm
Übungen: Sebastian Goebl

http://www.dbs.ifi.lmu.de/cms/ Einführung_in_die_Informatik_Systeme_und_Anwendungen

Überblick

3.2 Das Relationale Modell

- Charakteristika
  - Die Tabelle (Relation) ist das ausschließliche Strukturierungsmittel des relationalen Datenmodells
  - Edgar F. Codd, 1970
  - Konzept: vgl. Excel-Tabelle
  - Grundlage vieler kommerzieller DBS:

ORACLE

IBM Informix

Microsoft SQL Server

3.2 Das Relationale Modell

- Domain
  - Ein Wertebereich (oder Typ)
  - Logisch zusammengehörige Menge von Werten
  - Beispiele:
    - D_1 = Integer (ganze Zahlen {…, -2, -1, 0, 1, 2, …})
    - D_2 = String (Zeichenketten, z.B. „Hallo“)
    - D_3 = Date (Datum, typischerweise: TTMMYYYY)
    - D_4 = {rot, gelb, grün, blau}
    - D_5 = {1, 2, 3}
  - Kann ***endliche*** oder ***unendliche*** Kardinalität haben

3.2 Das Relationale Modell

- Kartesisches Produkt
  - Bedeutung des kartesisches Produkts (Kreuzprodukts) von k Domains:

    Menge von allen möglichen Kombinationen der Elemente der Mengen
  - Beispiel ($k = 2$):

    $D_1 = \{1, 2, 3\}$, $D_2 = \{a,b\}$

    $D_1 \times D_2 = \{(1,a), (1,b), (2,a), (2,b), (3,a), (3,b)\}$
  - Beispiel ($k = 3$):

    $D_1 = D_2 = D_3 = \mathcal{N}$

    $D_1 \times D_2 \times D_3 = \{(1,1,1),(1,1,2),(1,1,3),\ldots,(1,2,1),\ldots\}$

3.2 Das Relationale Modell

- Relation
  - Mathematische Definition:
    Relation R ist Teilmenge des kartesischen Produktes von k Domains $D_1, D_2, \ldots D_k$

$$R \subseteq D_1 \times D_2 \times \ldots \times D_k$$

  - Beispiel ($k = 2$):
    $D_1 = \{1, 2, 3\}$, $D_2 = \{a,b\}$

    $R_1 = \{\}$ (leere Menge, leere Relation)
    $R_2 = \{(1,a), (2,b)\}$
    $R_3 = \{(1,a), (2,a), (3,a)\}$
    $R_4 = D_1 \times D_2 = \{(1,a),(1,b),(2,a),(2,b),(3,a),(3,b)\}$

3.2 Das Relationale Modell

- Weiteres Beispiel:
  $D_1 = D_2 = \mathcal{N}$
  Relation R_1 = {(1,1),(1,2),(1,3),...,(2,2),(2,3),....,
  (3,3),(3,4),...(4,4),(4,5),(4,6),....}
  Wie heißt diese mathematische Relation?

$$\leq : R_{\leq} = \{(x, y) \in \mathcal{N} \times \mathcal{N} \mid x \leq y\}$$

- Es gibt endliche und unendliche Relationen
  (wenn mindestens eine Domain unendlich ist)
- In Datenbanksystemen: Nur endliche Relationen
  Unendlich: Nicht darstellbar

3.2 Das Relationale Modell

- Sprechweisen
  - Die einzelnen Domains lassen sich als ***Spalten einer Tabelle*** verstehen und werden als ***Attribute*** bezeichnet
  - Für $R \subseteq D_1 \times \ldots \times D_k$ ist k der ***Grad*** (***Stelligkeit***)
  - Die Elemente der Relation heißen Tupel:
    (1,a), (2,a), (3,a) sind drei Tupel vom Grad $k = 2$
  - Relation ist Menge von Tupeln
    d.h. die Reihenfolge der Tupel spielt ***keine*** Rolle
    {(0,a), (1,b)} = {(1,b), (0,a)}
  - Reihenfolge der Attribute ist von Bedeutung:
    {(a,0), (b,1)} ≠ {(0,a), (1,b)}

3.2 Das Relationale Modell

- Relationen und Datenbanken
  - Relationen sind die mathematische Formalisierung der ***Tabelle***
  - Jedes Tupel steht für einen Datensatz
  - Die einzelnen Informationen sind in den Attributwerten der Tupel gespeichert
  - Die Attribute können auch benannt sein:
    D_1 = Name: String
    D_2 = Vorname: String
  - Zeichenketten und Zahlen sind die häufigsten Domains

3.2 Das Relationale Modell

Alternative Definition:
Relation ist Ausprägung eines ***Relationen-Schemas***

- Geordnetes Relationenschema:
  - *k*-Tupel aus Domains (Attribute)
  - Attribute können benannt sein
  - Attribute werden anhand ihrer ***Position*** im Tupel referenziert

  $R = (A_1: D_1, \ldots A_k: D_k)$
- Domänen-Abbildung (ungeordnetes Relationenschema):
  - Relationenschema R ist Menge von Attributnamen:
  - Jedem Attributnamen A_i ist Domäne D_i zugeordnet:
  - Attribute werden anhand ihres ***Namens*** referenziert

  $R = \{A_1, \ldots A_k\}$ mit $\text{dom}(A_i) = D_i$, $1 \leq i \leq k$

3.2 Das Relationale Modell

- Beispiel: Städte-Relation

Städte

Name	Einwohner	Land
München	1.211.617	Bayern
Bremen	535.058	Bremen
Passau	49.800	Bayern

- Als geordnetes Relationenschema:

  Schema: Städte = (Name: String, Einwohner: Integer, Land: String)

  Ausprägung: {(München, 1.211.617, Bayern), (Bremen, 535.058, Bremen), (Passau, 49.800, Bayern)}

- Als Relationenschema mit Domänenabbildung:

  Schema: Städte = {Name, Einwohner, Land}
  mit dom(Name) = String, dom(Einwohner) = Integer, ...

  Ausprägung: $\{t_1, t_2, t_3\}$
  mit t_1(Name) = München, t_1(Einwohner) = 1.211.617,...

3.2 Das Relationale Modell

- Vorteil von geordnetem Relationenschema:
  - Prägnanter aufzuschreiben.
    Wichtig z.B. beim Einfügen neuer Tupel:
    t_3 = (Passau, 49.800, Bayern)
    vergleiche: t_3 (Name) = Passau; t_3 (Einwohner) = ...
- Nachteil von geordnetem Relationenschema:
  - Einschränkungen bei logischer Datenunabhängigkeit:
    Applikationen sensibel bzgl. Einfügung neuer Attribute (nur am Ende da sonst die Position der vorhandenen Attribute verändert wird)
- Definitionen gleichwertig
  (lassen sich ineinander überführen)
- Wir verwenden beide Ansätze

3.2 Das Relationale Modell

- Begriffe
  - Relation: Ausprägung eines Relationenschemas
  - Datenbankschema: Menge von Relationenschemata
  - Datenbank: Menge von Relationen (Ausprägungen)

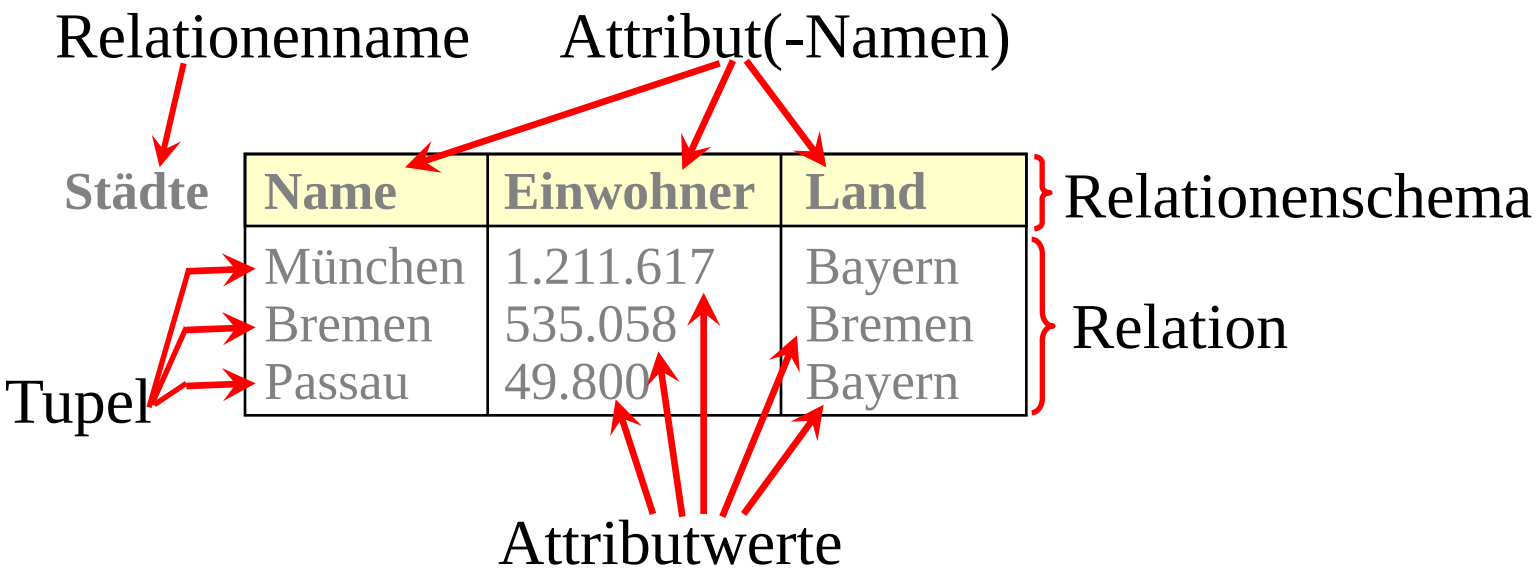

3.2 Das Relationale Modell

- Duplikate
  - Relationen sind Mengen von Tupeln.
    Konsequenzen:
    - Reihenfolge der Tupel irrelevant (wie bei math. Def)
    - Es gibt keine Duplikate (gleiche Tupel) in Relationen:
      {(0,a), (0,a), (0,a), (1,b)} = {(0,a), (1,b)}
  - Frage: Gilt dies auch für die Spalten beim ungeordneten Relationenschema $R = \{A_1,...,A_k\}$?
    - Die Reihenfolge der Spalten ist irrelevant
      (das ist gerade das Besondere am ungeordneten RS)
    - Duplikate treten nicht auf, weil alle Attribut-Namen verschieden sind

3.2 Das Relationale Modell

- Schlüssel
  - Tupel müssen eindeutig identifiziert werden
  - Warum? Z.B. für Verweise:

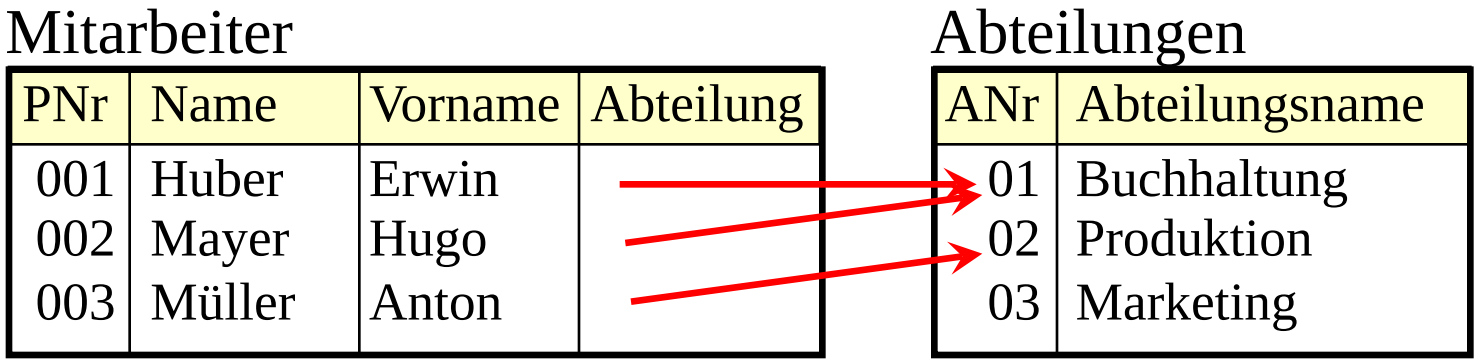

Mitarbeiter

PNr	Name	Vorname	Abteilung
001	Huber	Erwin	
002	Mayer	Hugo	
003	Müller	Anton	

Abteilungen

ANr	Abteilungsname
01	Buchhaltung
02	Produktion
03	Marketing

  - Objektidentifikation in Java:
    Mit Referenz (Adresse im Speicher)
  - Im relationalen Modell werden Tupel anhand von Attributwerten identifiziert
  - Ein/mehrere Attribute als ***Schlüssel*** kennzeichnen
  - Konvention: Schlüsselattribut(e) unterstreichen!

3.2 Das Relationale Modell

Beispiel: **PNr** und **ANr** werden Primärschlüssel:

Mitarbeiter

PNr	Name	Vorname	Abteilung
001	Huber	Erwin	
002	Mayer	Hugo	
003	Müller	Anton	

Abteilungen

ANr	Abteilungsname
01	Buchhaltung
02	Produktion
03	Marketing

- Damit müssen diese Attributswerte eindeutig sein!
- Verweis durch Wert dieses Schlüsselattributs:

Mitarbeiter

PNr	Name	Vorname	Abteilung
001	Huber	Erwin	01
002	Mayer	Hugo	01
003	Müller	Anton	02

Abteilungen

ANr	Abteilungsname
01	Buchhaltung
02	Produktion
03	Marketing

3.2 Das Relationale Modell

- Zusammengesetzter Schlüssel
  - Oft ist ein einzelnes Attribut nicht ausreichend, um die Tupel eindeutig zu identifizieren
- Beispiel:

Lehrveranstaltung

VNr	Titel	Semester
012	Einführung in die Informatik	WS 2001/02
012	Einführung in die Informatik	WS 2002/03
013	Medizinische Informationssyst.	WS 2001/02
...	...	...

  - Schlüssel: **(<u>VNr</u>, <u>Semester</u>)**
  - Anmerkung: Warum ist dies in diesem Fall ein schlechtes DB-Design?

3.2 Das Relationale Modell

Schlüssel:

Eine Teilmenge *S* der Attribute eines Relationenschemas *R* heißt ***Schlüssel***, wenn gilt:

- ***Eindeutigkeit***
  Keine Ausprägung von *R* kann zwei verschiedene Tupel enthalten, die sich in ***allen*** Attributen von *S* gleichen.
- ***Minimalität***
  Keine echte Teilmenge von *S* erfüllt bereits die Bedingung der Eindeutigkeit

3.2 Das Relationale Modell

In noch formalerer Notation:

Schlüssel:

- Sei r eine Relation über dem Relationenschema R und $S \subseteq R$ eine Auswahl von Attributen.
- $t[S]$ bezeichne ein Tupel t eingeschränkt auf die Attribute aus S (alle anderen Attribute gestrichen)
- (1) Eindeutigkeit:
  $\forall$ möglichen Ausprägungen r und Tupel $t_1, t_2 \in r$ gilt:
  $t_1 \neq t_2 \Rightarrow t_1[S] \neq t_2[S]$
- (2) Minimalität:
  Für alle Attributmengen S und T, die (1) erfüllen, gilt:
  $T \subseteq S \Rightarrow T = S$

3.2 Das Relationale Modell

- Beispiele
  - Gegeben sei die folgende Relation:

Lehrveranst

	LNr	VNr	Titel	Semester
t_1 →	1	012	Einführung in die Informatik	WS 2001/02
t_2 →	2	012	Einführung in die Informatik	WS 2002/03
t_3 →	3	013	Medizinische Informationssyst.	WS 2001/02
	...	...	...	...

  - {VNr} ist kein Schlüssel
    Nicht eindeutig: $t_1 \neq t_2$ **aber** $t_1[\text{VNr}] = t_2[\text{VNr}] = 012$
  - {Titel} ist kein Schlüssel
    (gleiche Begründung)
  - {Semester} ist kein Schlüssel
    Nicht eindeutig: $t_1 \neq t_3$ **aber** $t_1[\text{Semester}] = t_3[\text{Semester}]$

3.2 Das Relationale Modell

Lehrveranst

	LNr	VNr	Titel	Semester
t_1 →	1	012	Einführung in die Informatik	WS 2001/02
t_2 →	2	012	Einführung in die Informatik	WS 2002/03
t_3 →	3	013	Medizinische Informationssyst.	WS 2001/02
	...	...	...	...

- {LNr} ist Schlüssel !!!
  Eindeutigkeit: Alle t_i[LNr] sind paarweise verschieden,
  d.h. $t_1[LNr] \neq t_2[LNr]$, $t_1[LNr] \neq t_3[LNr]$, $t_2[LNr] \neq t_3[LNr]$
  Minimalität: Trivial, weil 1 Attribut kürzeste Möglichkeit

- {LNr, VNr} ist kein Schlüssel
  Eindeutigkeit: Alle t_i[LNr,VNr] paarweise verschieden.
  Nicht minimal, da ***echte*** Teilmenge {LNr} $\subset$ {LNr, VNr} ($\neq$)
  die Eindeutigkeit bereits gewährleistet, s.o.

3.2 Das Relationale Modell

Lehrveranst

	LNr	VNr	Titel	Semester
t_1 →	1	012	Einführung in die Informatik	WS 2001/02
t_2 →	2	012	Einführung in die Informatik	WS 2002/03
t_3 →	3	013	Medizinische Informationssyst.	WS 2001/02
	...	...	...	...

- {VNr, Semester} ist Schlüssel !!!
  Eindeutigkeit: Alle t_i[VNr, Semester] paarw. verschieden:
  - t_1 [VNr, Semester] = (012, WS 2001/02)
  - t_2 [VNr, Semester] = (012, WS 2002/03)
  - t_3 [VNr, Semester] = (013, WS 2001/02)

  Minimalität:
  Weder {VNr} noch {Semester} gewährleisten Eindeutigkeit (siehe vorher). Dies sind alle echten Teilmengen.

3.2 Das Relationale Modell

- Primärschlüssel
  - Minimalität bedeutet ***nicht*** :
    Schlüssel mit den wenigsten Attributen
  - Sondern Minimalität bedeutet:
    Keine überflüssigen Attribute sind enthalten
    (d.h. solche, die zur Eindeutigkeit nichts beitragen)
  - Manchmal gibt es mehrere verschiedene Schlüssel
    - {LNr}
    - {VNr, Semester}
  - Diese nennt man auch ***Schlüsselkandidaten***
  - Man wählt einen dieser Kandidaten aus als sog. ***Primärschlüssel***
    (oft den kürzesten, nicht immer)

3.2 Das Relationale Modell

- Die Eindeutigkeit bezieht sich ***nicht*** auf die aktuelle Ausprägung einer Relation *r*
- Sondern immer auf die ***Semantik*** der realen Welt

Mitarbeiter

PNr	Name	Gehalt
001	Müller	1700 €
002	Mayer	2172 €
003	Huber	3189 €
004	Schulz	2171 €

  - Bei der aktuellen Relation wären sowohl {PNr} als auch {Name} und {Gehalt} eindeutig.
  - Aber es ist möglich, dass mehrere Mitarbeiter mit gleichem Namen und/oder Gehalt eingestellt werden
  - {PNr} ist ***für jede mögliche*** Ausprägung eindeutig

3.2 Das Relationale Modell

- Definition eines Relationenschemas in SQL

```
CREATE TABLE n
  (
     a1 d1 c1,
     a2 d2 c2,
     ...
     ak dk ck
  )
```

← n Name der Relation

← Definition des ersten Attributs

← Definition des Attributs Nr. k

- hierbei bedeuten...
  - a_i der Name des Attributs Nr. i
  - d_i der Typ (die Domain) des Attributs
  - c_i ein optionaler Constraint für das Attribut

3.2 Das Relationale Modell

- Was passiert dabei?
  - Es wird eine leere Tabelle angelegt
  - Beispiel:

```
CREATE TABLE Mitarbeiter
 (
   PNr     NUMBER (3),
   Name    CHAR (20),
   Vorname CHAR (20),
   ANr     NUMBER (2)
 )
```

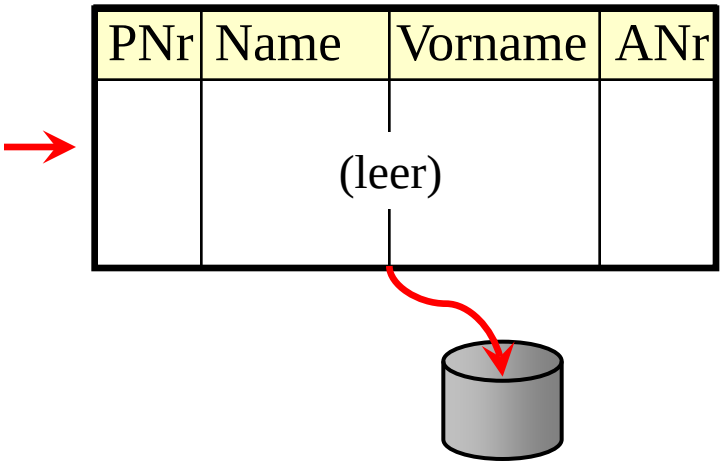

3.2 Das Relationale Modell

- Der SQL-Standard kennt u.a. folgende Basis-Datentypen (Domains):
  - **integer** oder auch **interger4**, **int**
  - **smallint** oder **integer2**
  - **float** (*p*) oder auch **float**
  - **decimal** (*p*,*q*) und **numeric** (*p*,*q*)
    mit *p* Stellen, davon *q* Nachkommast.
  - **character** (*n*), **char** (*n*) für Strings fester Länge *n*
  - **character varying** (*n*), **varchar** (*n*): variable Strings
  - **date, time, timestamp** für Datum und Zeit

3.2 Das Relationale Modell

- Einfache Zusätze (Integritätsbedingungen) können unmittelbar hinter einer Attributdefinition stehen:
  - **not null**: Das Attribut darf nicht undefiniert sein
    in DBS: undefinierte Werte heissen **null**-Werte
  - **primary key**: Das Attribut ist Primärschlüssel
    (nur bei 1-Attribut-Schlüsseln)
  - **check** *f*:
    Die Formel *f* wird bei jeder Einfügung überprüft
  - **references** t_1 (a_1):
    Ein Verweis auf Attribut a_1 von Tabelle t_1
    Verschiedene Zusatzoptionen:
    - **on delete cascade**
    - **on delete set null**
  - **default** w_1: Wert w_1 ist Default, wenn unbesetzt.

3.2 Das Relationale Modell

- Integritätsbedingungen

  Zusätze, die keinem einzelnen Attribut zugeordnet sind, stehen mit Komma abgetrennt in extra Zeilen

  - **primary key** (s_1, s_2, ...):
    Zusammengesetzter Primärschlüssel
  - **foreign key** (s_1, s_2, ...) **references** t_1 (...)
    Verweis auf zusammengesetzten Schlüssel in t_1
  - **check** f

- Anmerkung:
  SQL ist case-insensitiv:
  - im Ggs. zu Java hat die Groß-/Kleinschreibung weder bei Schlüsselworten noch bei Bezeichnern Bedeutung

3.2 Das Relationale Modell

Beispiele für Tabellendefinitionen

- Zusammengesetzter Primärschlüssel {VNr, Semester}:

```
create table Lehrveranst
  (
    LNr         integer         not null,
    VNr         integer         not null,
    Titel       varchar(50),
    Semester    varchar(20)     not null,
    primary key (VNr, Semester)
  )
```

- Alternative mit einfachem Primärschlüssel {LNr}:

```
create table Lehrveranst2
  (
    LNr         integer         primary key,
    VNr         integer         not null,
    Titel       varchar(50),
    Semester    varchar(20)     not null
  )
```

3.2 Das Relationale Modell

- Tabelle für Dozenten:

```
create table Dozenten
  (
    DNr       integer        primary key,
    Name      varchar(50),
    Geburt    date,
  )
```

- Verwendung von Fremdschlüsseln:

```
create table Haelt
  (
    Dozent    integer        references Dozenten (DNr)
                             on delete cascade,
    VNr       integer        not null,
    Semester  varchar(20)    not null,
    primary key (Dozent, VNr, Semester),
    foreign key (VNr, Semester) references Lehrveranst
  )
```

3.2 Das Relationale Modell

- Das Schlüsselwort **on delete cascade** in *Haelt* führt dazu, dass bei Löschen eines *Dozenten* auch entsprechende Tupel in *Haelt* gelöscht werden
- Weitere Konstrukte der Data Definition Language:
  - **drop table** n_1
    Relationen-Schema n_1 wird mit allen evtl. vorhandenen Tupeln gelöscht.
  - **alter table** n_1 **add** (a_1 d_1 c_1, a_2 d_2 c_2, ...)
    - Zusätzliche Attribute oder Integritätsbedingungen werden (rechts) an die Tabelle angehängt
    - Bei allen vorhandenen Tupeln Null-Werte
  - **alter table** n_1 **drop** (a_1 , a_2 , ...)
  - **alter table** n_1 **modify** (a_1 d_1 c_1, a_2 d_2 c_2, ...)