Ludwig Maximilians Universität München
Institut für Informatik
Lehr- und Forschungseinheit für Datenbanksysteme

Skript zur Vorlesung

# Datenbanksysteme I

Wintersemester 2010/2011

# Kapitel 2: Das Relationale Modell

Vorlesung: PD Dr. Matthias Schubert
Übungen: Thomas Bernecker, Andreas Züfle


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

# Charakteristika



- Einführungskapitel:
  Viele Informationen darstellbar als Tabelle
- Die Tabelle (Relation) ist das ausschließliche Strukturierungsmittel des relationalen Datenmodells
- Edgar F. Codd, 1970.
- Grundlage vieler kommerzieller DBS:

Informix

# Domain

- Ein Wertebereich (oder Typ)
- Logisch zusammengehörige Menge von Werten
- Beispiele:
  - $D_1$ = Integer
  - $D_2$ = String
  - $D_3$ = Date
  - $D_4$ = {rot, gelb, grün, blau}
  - $D_5 = \{1, 2, 3\}$
- Kann *endliche* oder *unendliche* Kardinalität haben





# Kartesisches Produkt

- Bedeutung kartesisches Produkt (Kreuzprodukt)?
  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 ($k = 3$):
  $D_1 = D_2 = D_3 = \mathcal{N}$
  $D_1 \times D_2 \times D_3 = \{(1,1,1),(1,1,2),(1,1,3),\ldots,(1,2,1),\ldots\}$

# Relation

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

$$\boxed{R \subseteq D_1 \times D_2 \times ... \times D_k}$$

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

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



# Relation

- 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?

$$\leq \qquad R_1 = \{(x, y) \in \mathcal{N} \times \mathcal{N} \mid x \leq y\}$$

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

# Relation

- Die einzelnen Domains lassen sich als Spalten einer Tabelle verstehen und werden als Attribute bezeichnet
- Für $R \subseteq D_1 \times ... \times D_k$ 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: $\{(a,0), (b,1)\} \neq \{(0,a), (1,b)\}$





# Relation

- 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

# Relationen-Schema



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 ref.

  $R = (A_1: D_1, \ldots A_k: D_k)$

- Domänen-Abbildung (ungeordnetes Rel.-Sch.):
  - 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 $\mathrm{dom}(A_i) = D_i,\ 1 \le i \le k$



# Relationen-Schema



- Beispiel: Städte-Relation

**Städte**

| **Name** | **Einwohner** | **Land** |
|---|---|---|
| München | 1.211.617 | Bayern |
| Bremen | 535.058 | Bremen |
| Passau | 49.800 | Bayern |

- Als geordnetes Relationenschema:
  Schema: $R$ = (Name: String, Einwohner: Integer, Land: String)
  Ausprägung: $r$ = {(München, 1.211.617, Bayern), (Bremen, 535.058, Bremen), (Passau, 49.800, Bayern)}

- Als Relationenschema mit Domänenabbildung:
  Schema: $R$ = {Name, Einwohner, Land}
  mit dom(Name) = String, dom(Einwohner) = Integer, ...
  Ausprägung: $r = \{t_1, t_2, t_3\}$
  mit $t_1$(Name) = München, $t_1$(Einwohner) = 1.211.617,...

# Diskussion

- 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!)
- Definitionen gleichwertig
  (lassen sich ineinander überführen)
- Wir verwenden beide Ansätze





# Begriffe

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

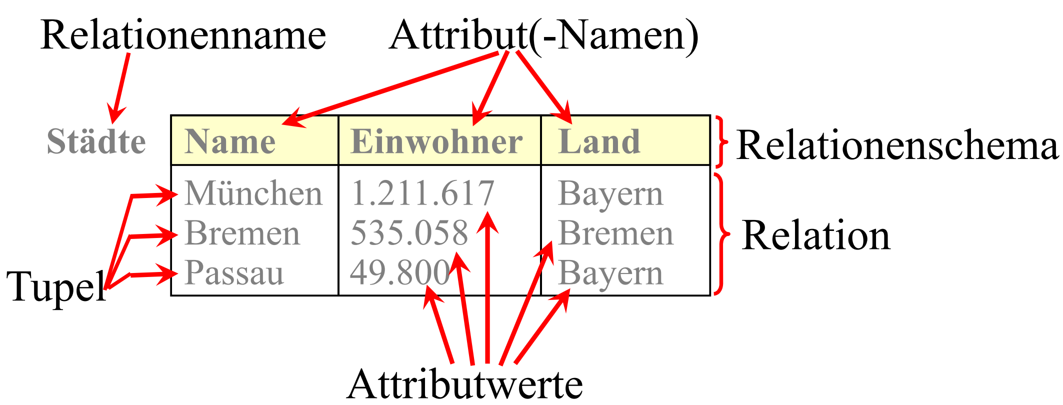

# Duplikate

- 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 $R = \{A_1,...,A_k\}$ ?
  - Reihenfolge der Spalten ist irrelevant
    (das ist gerade das besondere am ungeordneten RS)
  - Duplikate treten nicht auf, weil alle Attribut-Namen verschieden





# 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!

# Schlüssel

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 |



# 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: **(VNr, Semester)**
- Anmerkung: Warum ist dies ein schlechtes DB-Design?
  Nicht redundanzfrei:
  Der Titel ist mehrfach in der Datenbank gespeichert

# Schlüssel: Formale Definition

Definition:

- 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



# Schlüssel: Formale Definition

In noch formalerer Notation:

Definition:

- 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:
  $T \subseteq S \Rightarrow T = S$

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





# Schlüssel: Beispiele

**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]≠$t_2$[LNr], $t_1$[LNr]≠$t_3$[LNr], $t_2$[LNr]≠$t_3$[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} ⊂ {LNr, VNr} (≠) die Eindeutigkeit bereits gewährleistet, s.o.

Datenbanksysteme I
Kapitel 2: Das Relationale Modell

# Schlüssel: Beispiele

| 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.



# Primärschlüssel

- Minimalität bedeutet **nicht**:
  Schlüssel mit den wenigsten Attributen
- Sondern Minimalität bedeutet:
  **Keine überflüssigen Attribute sind enthalten**
  (d.h. solche, die zur Eindeutikeit 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)

# Schlüssel: Semantische Eigenschaft

- 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



# Tabellendefinition in SQL

- Definition eines Relationenschemas:

**CREATE TABLE** *n* ← *n* Name der Relation
(
$a_1\ d_1\ c_1$, ← Definition des ersten Attributs
$a_2\ d_2\ c_2$,
...
$a_k\ d_k\ c_k$ ← 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

# Basis-Typen in SQL

Der SQL-Standard kennt u.a. folgende Datentypen:

- **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



# Zusätze bei Attributdefinitionen

- 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.

# 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



# Beispiel Tabellendefinition

- 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
  )
```

# Beispiel Tabellendefinition

- 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
  )
```



# Beispiel Tabellendefinition

- 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** $(a_1\ d_1\ c_1,\ a_2\ d_2\ c_2, \ldots)$
    - Zusätzliche Attribute oder Integritätsbedingungen werden (rechts) an die Tabelle angehängt
    - Bei allen vorhandenen Tupeln Null-Werte
  - **alter table** $n_1$ **drop** $(a_1, a_2, \ldots)$
  - **alter table** $n_1$ **modify** $(a_1\ d_1\ c_1,\ a_2\ d_2\ c_2, \ldots)$