Datenbankbasierte Web-Anwendungen

Datenabfragen ueber mehrere Tabellen und Normalisierung

Medieninformatik SoSe 2017

Renzo Kottmann

Zusammenfassung der vorherigen Vorlesung

- Foreign Keys zur Umsetzung von Beziehungen
- Von Anfragen zu SQL-Abfragen
- Transaktionen

Aktuelle Implementierung

- SQL file mit ersten Testdaten

Abfragen über mehrere Tabellen

Revisited: Anatomie von SELECT

```
SELECT *         -- welche Spalten sollen wie angezeigt werden
  FROM tabelle   -- Daten welcher Tabelle
 WHERE true      -- Selektionesbedingungen: nur Daten, die Kriterium entsprechen
```

Kann gelesen werden als:

```
Zeige mir alle Spalten der Tabelle "tabelle" an und davon alle Zeilen.
```

Revisited: Anatomie von SELECT

```
SELECT *         -- welche Spalten sollen wie angezeigt werden
  FROM tabelle   -- Daten welcher Tabelle
 WHERE true      -- Selektionesbedingungen: nur Daten, die Kriterium entsprechen
```

Kann gelesen werden als:

```
Zeige mir alle Spalten der Tabelle "tabelle" an und davon alle Zeilen.
```

Es wird immer eine und nur eine Tabelle durch `SELECT` erzeugt, daher ist das technisch präziser:

```
Erzeuge und zeig mir *eine* virtuelle Tabelle, die folgender Anweisung enpricht:
Zeige alle Spalten der Tabelle "tabelle" an und davon alle Zeilen.
```

Beispiel-Tabellen

```
TabelleA      TabelleB
id name       id  name
-- ----       --  ----
1  Pirate     1   Rutabaga
2  Monkey     2   Pirate
3  Ninja      3   Darth Vader
4  Spaghetti  4   Ninja
```

INNER JOIN

```
SELECT *
  FROM TabelleA AS a
       INNER JOIN
       TabelleB as b
    ON a.name = b.name
```

```
id  name       id   name
--  ----       --   ----
1   Pirate     2    Pirate
3   Ninja      4    Ninja
```

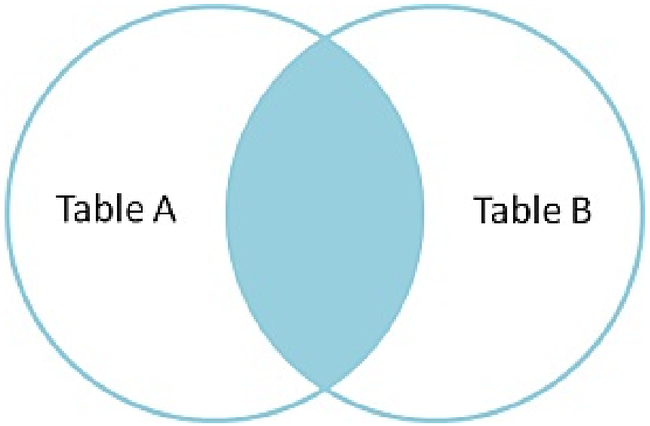

FULL OUTER JOIN

```
SELECT *
  FROM TabelleA as a
       FULL OUTER JOIN
       TabelleB as b
    ON a.name = b.name
```

```
id    name       id    name
--    ----       --    ----
1     Pirate     2     Pirate
2     Monkey     null  null
3     Ninja      4     Ninja
4     Spaghetti  null  null
null  null       1     Rutabaga
null  null       3     Darth Vader
```

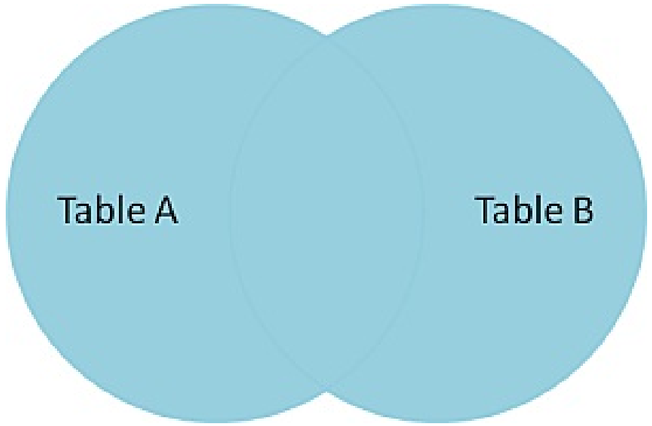

LEFT OUTER JOIN

```
SELECT *
  FROM TabelleA AS a
       LEFT OUTER JOIN
       TabelleB AS b
    ON a.name = b.name
```

```
id  name       id    name
--  ----       --    ----
1   Pirate     2     Pirate
2   Monkey     null  null
3   Ninja      4     Ninja
4   Spaghetti  null  null
```

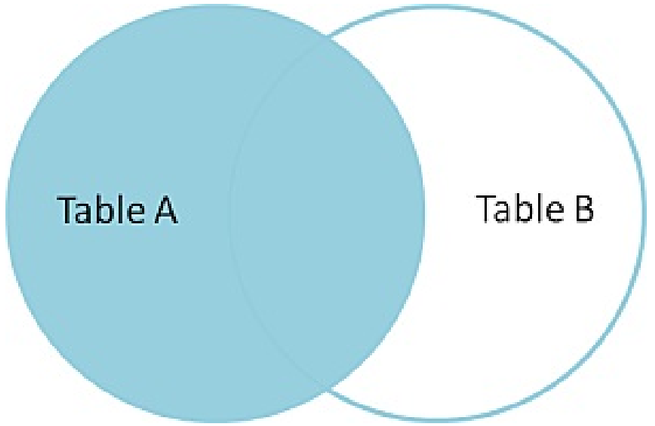

LEFT OUTER JOIN: nur Zeilen von TabelleA

```
SELECT *
  FROM TabelleA AS a
       LEFT OUTER JOIN
       TabelleB AS b
    ON a.name = b.name
 WHERE b.id IS null
```

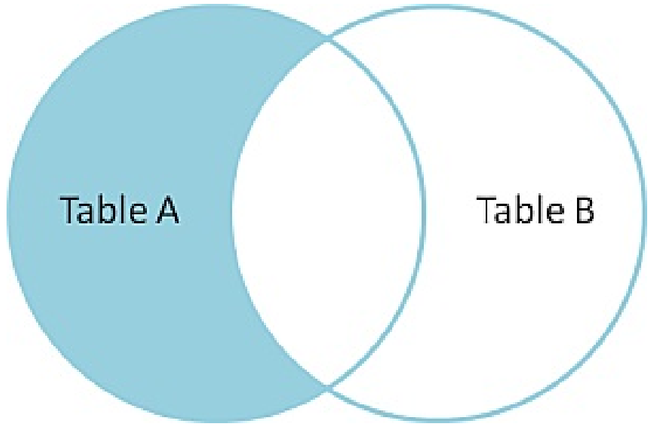

id	name	id	name
2	Monkey	null	null
4	Spaghetti	null	null

FULL OUTER JOIN: nur exklusive Zeilen

```
SELECT *
  FROM TabelleA AS a
       FULL OUTER JOIN
       TabelleB AS b
    ON a.name = b.name
 WHERE a.id IS null
       OR
       b.id IS null
```

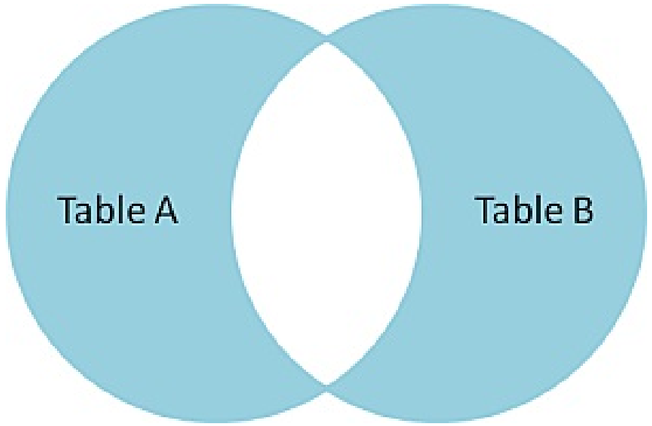

id	name	id	name
2	Monkey	null	null
4	Spaghetti	null	null
null	null	1	Rutabaga
null	null	3	Darth Vader

CROSS JOIN: Erzeugt kartesiches Produkt

```
SELECT *
  FROM TabelleA
       CROSS JOIN
       TabelleB
```

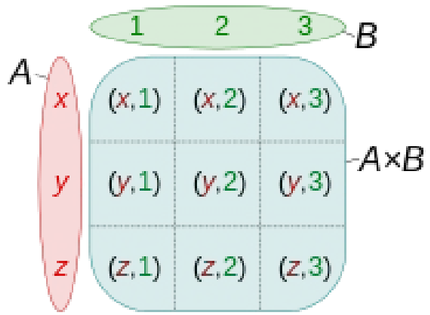

In einfachen Worten: Verbindet jede Zeile der TabelleA mit jeder Zeile der TabelleB

SQL JOINS

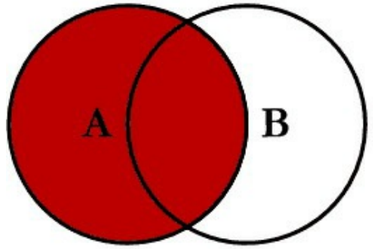


```
SELECT <select_list>
FROM TableA A
LEFT JOIN TableB B
ON A.Key = B.Key
```

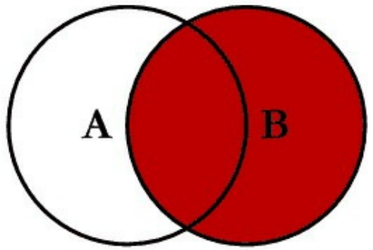


```
SELECT <select_list>
FROM TableA A
RIGHT JOIN TableB B
ON A.Key = B.Key
```

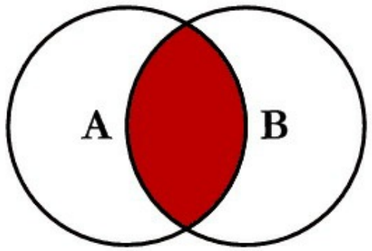


```
SELECT <select_list>
FROM TableA A
INNER JOIN TableB B
ON A.Key = B.Key
```

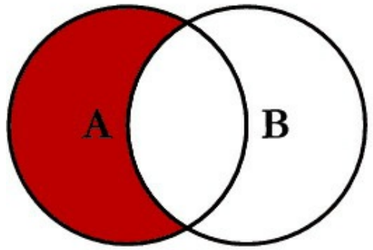


```
SELECT <select_list>
FROM TableA A
LEFT JOIN TableB B
ON A.Key = B.Key
WHERE B.Key IS NULL
```

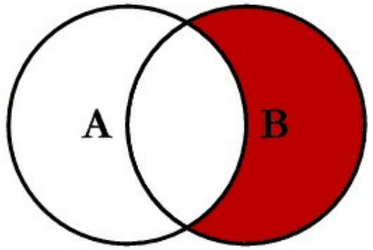


```
SELECT <select_list>
FROM TableA A
RIGHT JOIN TableB B
ON A.Key = B.Key
WHERE A.Key IS NULL
```

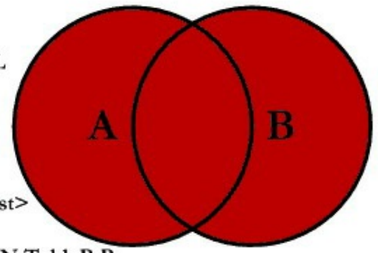


```
SELECT <select_list>
FROM TableA A
FULL OUTER JOIN TableB B
ON A.Key = B.Key
```

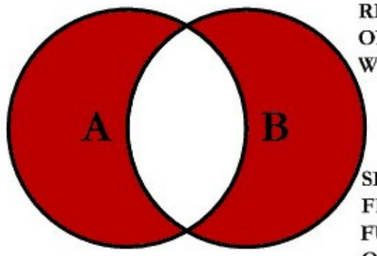


```
SELECT <select_list>
FROM TableA A
FULL OUTER JOIN TableB B
ON A.Key = B.Key
WHERE A.Key IS NULL
OR B.Key IS NULL
```

Diskussion zu Visualisierung von SQL-joins

- Original Artikel mit Venn-Overview
- Diskussion und alternative Darstellung
- Kategorisierung nach JOIN-Typen

Datenbank: Query Plan

- Jede Abfrage wird vom DBMS ausgewertet
  - DBMS findet einen optimalen Plan zur Ausführung der Abfrage
  - DBMS bestimmt einen optimalen Algorithmus!

Logische Ausführung vs. Aktuelle Ausführung

- SQL standard legt eine logische Auswertungsreihenfolge fest
- DBMS kann intern davon abweichen

Logische Ausführungsreihenfolge

(1) FROM, JOIN, APPLY

(2) WHERE

(3) CONNECT BY (Oracle)

(4) GROUP BY

(5) AGGREGATIONS

(6) HAVING

(7) WINDOW

(8) MODEL (Oracle)

(9) SELECT

(10) DISTINCT

(11)UNION, INTERCEPT, EXCEPT

(12) ORDER BY

(13) OFFSET

(14) LIMIT

(15) FOR UPDATE

Es geht noch viel mehr mit SQL

(1) FROM, JOIN, APPLY

(2) WHERE

(3) CONNECT BY (Oracle)

(4) GROUP BY

(5) AGGREGATIONS

(6) HAVING

(7) WINDOW

(8) MODEL (Oracle)

(9) SELECT

(10) DISTINCT

(11)UNION, INTERCEPT, EXCEPT

(12) ORDER BY

(13) OFFSET

(14) LIMIT

(15) FOR UPDATE

[1] Gesamtüberblick

[2] SELECT Details

Normalisierung

Fiktive Teilnehmerinnen Tabelle

Name	Nachname	MatrikelNummer (Primary Key)	emails	Klausur	Aufgabe	Strasse	Ort	PLZ
Ricarda	Huch	123456	huch@stud.hs-bremen.de, ric@gmail.com	FALSE	Buchhandlung	S 1	HB	23
Greta	Garbo	234567	great@web.de, garbo@hollywood.com	FALSE	Filmsammlung	S 1	HH	44
Emma	Goldman	345678	libertat@gmx.de	FALSE	Buchhandlung	S 3	HB	44

- Diese Tabelle ist nicht **Normal**, voll von **Anomalien**.

Update-Anomalien

1. Modifikation: Die Datenbank muss an mehreren Stellen geändert werden, um Einträge zu ändern. Beispiel: wenn der Name der Aufgabe von Buchhandlung in Buchhandlungen geändert werden soll.

2. Einfügung: Um einen Eintrag in eine Tabelle vorzunehmen, müssen nicht reale Werte erfunden werden. Beispiel: Um eine neue Aufgabe einzufügen, muss eine 'MatrikelNummer' erfunden werden, da MatrikelNummer Primärschlüssel ist.

3. Löschung: Um einen Eintrag zu löschen, müssen auch ungewollt andere Einträge gelöscht werden: Beispiel: Um die Aufgabe 'Filmsammlung' zu löschen, muss MatrikelNummer (und somit die gesamte Zeile) gelöscht werden.

Entwurfs-Ziel

Entwerfe ein relationales Datenbank-Model derart, dass keine Upate-Anomalien vorkommen können.

Funktionale Abhängigkeit

- Begriff gehört zur Normalisierung

Definition: Funktionale Abhängigkeit

Seien X und Y beliebige Teilmengen der Attribute einer Tabelle T. Dann ist Y von X funktional abhängig, wenn gilt

> für jede Wertekombination von X gibt es – zu einem gegebenen Zeitpunkt – nur eine Wertekombination von Y.

Definition: Funktionale Abhängigkeit

Seien X und Y beliebige Teilmengen der Attribute einer Tabelle T. Dann ist Y von X funktional abhängig, wenn gilt

> für jede Wertekombination von X gibt es – zu einem gegebenen Zeitpunkt – nur eine Wertekombination von Y.

Wenn die Werte von X feststehen, stehen auch die Werte von Y fest.

Auch wenn Y noch nicht bekannt ist, kann es nur eine Wertekombination von Y zu X geben.

Anders: Es kann zu keinem Zeitpunkt zweimal dieselben Werte für X geben, aber jeweils verschiedene Werte für Y.

Das heißt:

> X determiniert Y funktional $X \rightarrow Y$

Beipiele

Sei A die Menge aller Attribute der Relation Teilnehmerinnen,

mit:

1. X = {MatrikelNummer},
   dann gilt X → A denn X ist Primärschlüssel

2. Y = {Name},
   dann **gilt nicht** Y → A. Denn es kann mehrere Teilnehmerinnen mit demselben Namen geben.

3. O = {Ort, Strasse}, P = {PLZ},
   dann kann O → P gelten, muss aber nicht

Funktionale Abhängigkeiten sind Kontext-Abhängig

Beispiel:

1. O = {Ort, Strasse}, P = {PLZ},
   dann kann O → P gelten, muss aber nicht

- Gilt evtl. nur in Bremen bzw. bestimmten Regionen
- Aber nicht allgemein in Deutschland
  (s. Unterstein und Matthiessen S. 241)

1. Normalform

- Eine Datenbank ist in 1. Normalform (1NF), wenn alle Attribute atomar sind.
  D.h. jedes Attribut enthält nur einen Wert der immer als unzerteilbare Einheit betrachtet wird.

1. Normalform(isierung)

Name	Nachname	MatrikelNummer (Primary Key)	emails	Klausur	Aufgabe	Strasse	Ort	PLZ
Ricarda	Huch	123456	huch@stud.hs-bremen.de, ric@gmail.com	FALSE	Buchhandlung	S 1	HB	23
Greta	Garbo	234567	great@web.de, garbo@hollywood.com	FALSE	Filmsammlung	S 1	HH	44
Emma	Goldman	345678	libertat@gmx.de	FALSE	Buchhandlung	S 3	HB	44

2. Normalform (2NF)

- Eine Relation ist in 2. Normalform (2NF),
  - wenn sie 1NF erfüllt und jedes Attribut, das nicht zum Primärschlüssel gehört, voll von diesem abhängig ist.

  - "Alle Attribute, die nicht Teil des Schlüssels sind, hängen voll funktional von diesem ab."

  Ist der Primärschlüssel einfach, so ist 2NF trivialerweise erfüllt.
  Daher ist die obige Tabelle schon in 2NF.

Verstoss gegen 2. Normalform

Folgendes schematisches Beispiel verdeutlicht einen Verstoss:

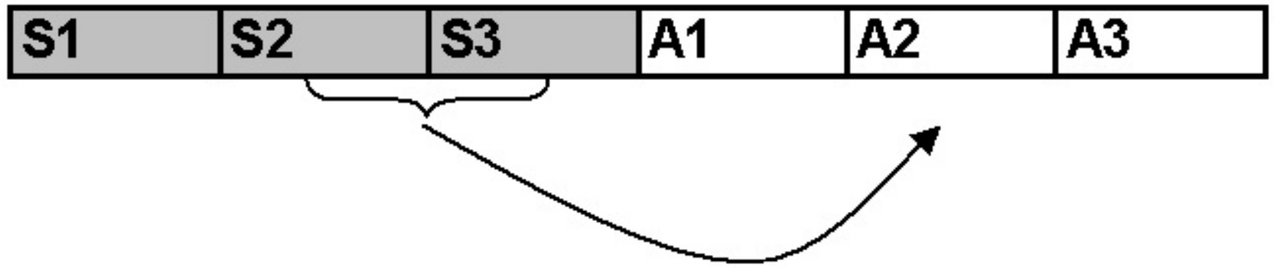

Verstoß gegen 2. Normalform

3. Normalform (3NF)

"Eine Relation ist in der dritten Normalform, wenn für jede nicht triviale funktionale Abhängigkeit T → A mit T Obermenge eines Schlüssels ist oder A (mindestens) ein Primattribut enthält."

- Aus 2NF und Minimalität des Schlüssels ergibt sich, dass T mindestens ein Nichtschlüsselattribut enthalten muss, um gegen 3NF zu verstoßen.

3. Normalform (3NF) informal

Eine Relation ist 3NF genau dann, wenn die nicht Schlüsselattribute (nicht Teil des Primary Key) beide Eigenschaften haben:

1. voneinander unabhängig
2. unwiderruflich abhängig vom Primary Key

3. Normalform (3NF) informal

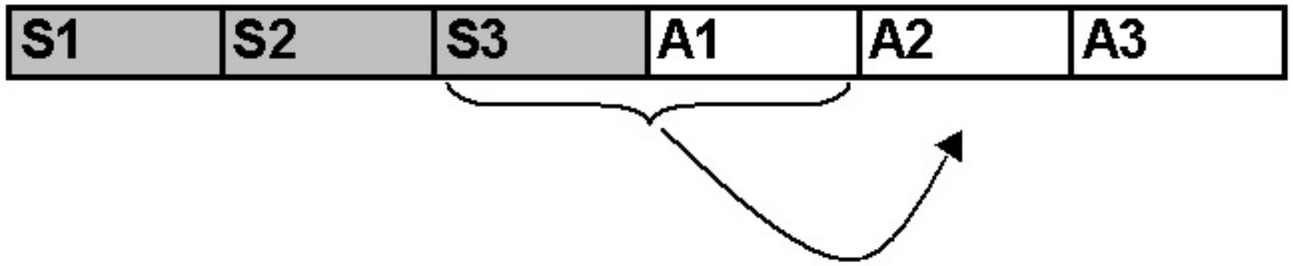

Verstoß gegen 3. Normalform

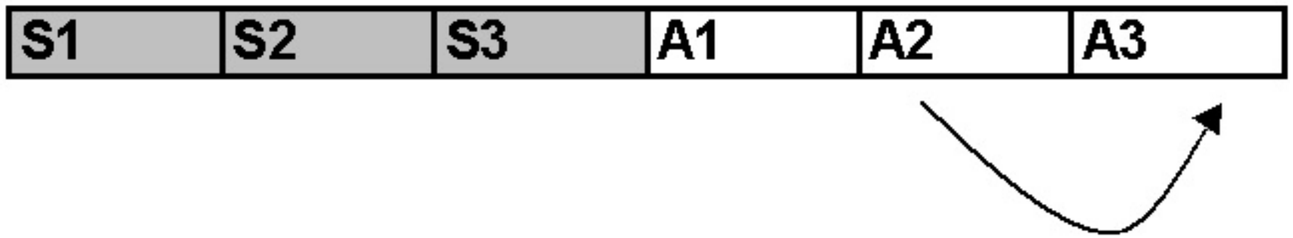

Verstoß gegen 3. Normalform, einfacher Fall

Boyce-Codd Normalform (BCNF)

"Eine Relation ist in der Boyce-Codd Normalform, wenn für jede nicht triviale funktionale Abhängigkeit T → A mit T Obermenge eines Schlüssels ist oder A (mindestens) ein Primattribut enthält."

- Es gibt keine transitiven funktionalen Abhängigkeiten. Aus S → A darf sich nicht A → T ableiten lassen.
- Alle funktionalen Abhängigkeiten sind vom Primary Key abhängig

Meine Vorgehensweise

- Alles was, gemäss den Anforderungen, eigenständig und unabhängig von existiereneden Entitäten gemanaged werden muss, ist eine neue eigenständige Entität oder neue Beziehung zwischen Entität.
- Managen heisst: Alles was zu unterschiedlichen Zeiten erst ins System kommt und eigene `insert`, `update`, und `delete` Regeln hat.

Normalisierung: Weitere Vorgehensweisen

- 5 Regeln:
  http://www.databaseanswers.org/downloads/Marc_Rettig_5_Rules_o
- J. Celko's 13 Regeln:
  - Wichtigste: If you have to change more than one row to update, insert or delete a simple fact, then the table is not normalized.

- Does the table model either a set of one and only one kind of entity or one and only one relationship. This is what I call disallowing a “Automobiles, Squids and Lady GaGa” table. Following this rule will prevent ‘Multi-valued dependencies’ (MVD) problems and it is the basis for the other heuristics.

- Does the entity table make sense? Can you express the idea of the table in a simple collective or plural noun? To be is to be something in particular; to be everything in general or nothing in particular is to be nothing at all (this is known as the Law of Identity in Greek logic). This is why EAV does not work – it is everything and anything.

- Do you have all the attributes that describe the thing in the table? In each row? The most important leg on a three-legged stool is the leg that is missing.

- Are all the columns scalar? Or is a column serving more than one purpose? Did you actually put hat size and shoe size in one column? Or store a CSV list in it?

- Do not store computed values, such as (unit_price * order_qty). You can compute these things in VIEWs or computed columns.

- Does the relationship table make sense? Can you express the idea of the table in a simple sentence, or even better, a name for the relationship? The relationship is “marriage” and not “person_person_legal_thing”

- Did you check to see if the relationship is 1:1, 1:m or n:m? Does the relationship have attributes of its own? A marriage has a date and a license number that does not belong to either of the people involved. This is why we don't mind tables that model 1:1 relationships.

- Does the entity or relationship have a natural key? If it does, then you absolutely have to model it as the PRIMARY KEY or a UNIQUE constraint. Is there a standard industry identifier for it? Let someone else do all that work for you.

- If you have a lot of NULL-able columns, the table is probably not normalized.

- The NULLs could be non-related entities or relationships.

- Do the NULLs have one and only one meaning in each column?

- If you have to change more than one row to update, insert or delete a simple fact, then the table is not normalized.

- Did you confuse attributes, entities and values? Would you split the Personnel table into “Male_Personnel” and ”Female_Personnel” by splitting out the sex code? No, sex is an attribute and not an entity. Would you have a column for each shoe size? No, a shoe size is a value and not an attribute.