Name:
Klasse:
Datum:
Schuljahr: 2022/23

Daten importieren

Oft ist es notwendig, Daten von anderen Quellen zu importieren. Hat man einen großen Kundenkreis, ist es sehr aufwendig, jedes Mal bei einem neuen Kunden die PLZ bzw. den Ort einzugeben. Auf der Seite www.suche-postleitzahl.org kann man sich die Daten von Deutschland herunterladen. Die Daten stehen unter der Open Database Licence frei zur Verfügung.

```
osm_id,ags,ort,plz,landkreis,bundesland
1104550,08335001,Aach,78267,Landkreis Konstanz,Baden-Württemberg
1255910,07235001,Aach,54298,Landkreis Trier-Saarburg,Rheinland-Pfalz
62564,05334002,Aachen,52062,Städteregion Aachen,Nordrhein-Westfalen
62564,05334002,Aachen,52064,Städteregion Aachen,Nordrhein-Westfalen
62564,05334002,Aachen,52066,Städteregion Aachen,Nordrhein-Westfalen
62564,05334002,Aachen,52068,Städteregion Aachen,Nordrhein-Westfalen
62564,05334002,Aachen,52070,Städteregion Aachen,Nordrhein-Westfalen
```

Das Format entspricht nicht unserem Datenschema - es muss also schrittweise angepasst werden.

Für die weiteren Schritte verwenden wir die Datenbank `gm1` mit den schon vorhandenen Tabellen, u. a. die Tabelle `ort`!

```
MariaDB [gm1]> show tables;
+---------------+
| Tables_in_gm1 |
+---------------+
| abteilung     |
| gehalt        |
| mitarbeiter   |
| ort           |
+---------------+
```

1. **Temporäre Tabelle für die CSV-Daten anlegen.**
   Die Struktur entspricht dabei genau der CSV-Datei. Die Spaltenbreite wurde hier großzügig bemessen. Entspricht die Spaltenreihenfolge der Reihenfolge der CSV-Datei, so muss beim Import bzgl. der Spalten nichts zusätzlich angegeben werden. Für die Tabelle ist kein PK notwendig, da diese dann später sequentiell komplett gelesen wird (full table scan).

   ```
   CREATE TABLE csv_ort (
     osm_id     VARCHAR(20),
     ags        VARCHAR(20),
     ort        VARCHAR(50),
     plz        VARCHAR(10),
     landkreis  VARCHAR(50),
     bundesland VARCHAR(50)
   ) ENGINE=InnoDB DEFAULT CHARSET=utf8;
   ```

   ```
   MariaDB [gm1]> desc csv_ort;
   +------------+-------------+------+-----+---------+-------+
   | Field      | Type        | Null | Key | Default | Extra |
   +------------+-------------+------+-----+---------+-------+
   | osm_id     | varchar(20) | YES  |     | NULL    |       |
   | ags        | varchar(20) | YES  |     | NULL    |       |
   | ort        | varchar(50) | YES  |     | NULL    |       |
   | plz        | varchar(10) | YES  |     | NULL    |       |
   | landkreis  | varchar(50) | YES  |     | NULL    |       |
   | bundesland | varchar(50) | YES  |     | NULL    |       |
   +------------+-------------+------+-----+---------+-------+
   ```

2. **Datenimport** (für Text-Dateien) wird über den Befehl LOAD DATA INFILE realisiert.
   Der Verzeichniseintrag, in dem die CSV-Datei abgespeichert worden ist, muss natürlich entsprechend angepasst werden!

```
LOAD DATA LOCAL INFILE 'src/csv/zuordnung_plz_ort_landkreis.csv'
   INTO TABLE csv_ort
   CHARACTER SET utf8
   FIELDS TERMINATED BY ','
   LINES TERMINATED BY '\n'
   IGNORE 1 ROWS;
```

   Die Ausgabe ist dabei:

```
Query OK, 12937 rows affected (0.212 sec)
Records: 12937  Deleted: 0  Skipped: 0  Warnings: 0
```

   Achtung:
   Bei einigen Distributionen ist der Befehl `LOAD DATA LOCAL INFILE` aus Sicherheitsgründen deaktiviert.
   Wenn dies bei Ihnen der Fall ist, so ändern Sie die Einstellungen. Siehe hierzu Server prints bad error message when user executes LOAD DATA LOCAL and it is disabled

```
The used command is not allowed with this MariaDB version
```

   oder

```
The used command is not allowed because the MariaDB server or client has ⤸
disabled the local infile capability
```

   Die Tabelle hat folgenden Inhalt:

```
select ort,plz,landkreis,bundesland from csv_ort limit 4;
+--------+-------+--------------------------+---------------------+
| ort    | plz   | landkreis                | bundesland          |
+--------+-------+--------------------------+---------------------+
| Aach   | 78267 | Landkreis Konstanz       | Baden-Württemberg   |
| Aach   | 54298 | Landkreis Trier-Saarburg | Rheinland-Pfalz     |
| Aachen | 52062 | Städteregion Aachen      | Nordrhein-Westfalen |
| Aachen | 52064 | Städteregion Aachen      | Nordrhein-Westfalen |
+--------+-------+--------------------------+---------------------+
```

   Da die Tabelle fast 13.000 Datensätze enthält, ist es sinnvoll, auf die Spalten `ort`, `landkreis` und `bundesland` einen Index zu legen. Der Index sorgt dafür, dass die Spalte über den Index sortiert ist. Somit wird der Zugriff deutlich schneller, wenn man z. B. nur alle Landkreise anzeigen lassen will, die in Bayern sind. Der Nachtteil, der Index benötigt zusätzlich Speicher.

   Informieren Sie sich über den Befehl CREATE INDEX.

Notiz:

Index für die Spalten anlegen:

```
CREATE OR REPLACE INDEX csv_ort_bundesland ON csv_ort (bundesland);
CREATE OR REPLACE INDEX csv_ort_landkreis ON csv_ort (landkreis);
CREATE OR REPLACE INDEX csv_ort_ort ON csv_ort (ort);
```

Mit dem Befehl `SHOW INDEX` werden die Indexe zu einer Tabelle angezeigt.
Der Anhang `\G` sorgt dafür, dass die Ausgabe vertikal erfolgt.

Wird eine Tabelle gelöscht, werden automatisch alle Indexe gelöscht.

```
MariaDB [gm1]> show index from csv_ort\G
*************************** 1. row ***************************
        Table: csv_ort
   Non_unique: 1
     Key_name: csv_ort_bundesland
 Seq_in_index: 1
  Column_name: bundesland
    Collation: A
  Cardinality: 32
     Sub_part: NULL
       Packed: NULL
         Null: YES
   Index_type: BTREE
      Comment:
Index_comment:
*************************** 2. row ***************************
        Table: csv_ort
   Non_unique: 1
     Key_name: csv_ort_landkreis
 Seq_in_index: 1
  Column_name: landkreis
    Collation: A
  Cardinality: 596
     Sub_part: NULL
       Packed: NULL
         Null: YES
   Index_type: BTREE
      Comment:
Index_comment:
*************************** 3. row ***************************
        Table: csv_ort
   Non_unique: 1
     Key_name: csv_ort_ort
 Seq_in_index: 1
  Column_name: ort
    Collation: A
  Cardinality: 13132
     Sub_part: NULL
       Packed: NULL
         Null: YES
   Index_type: BTREE
      Comment:
Index_comment:
```


3. **Tabellen ergänzen bzw. anpassen**

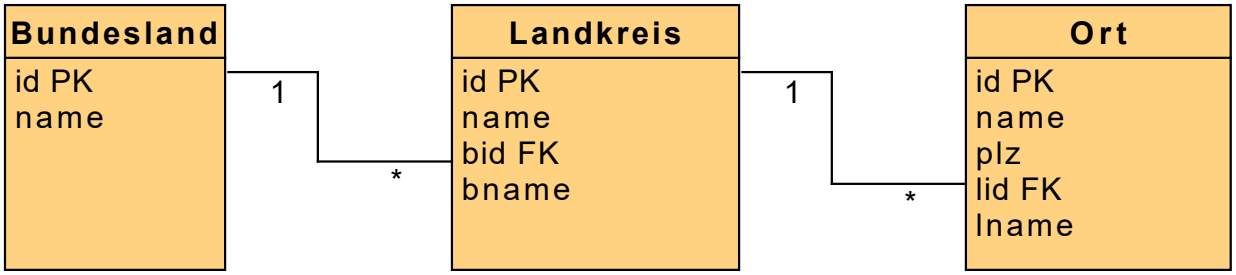

Damit im nächsten Schritt die `bid` ermittelt werden kann, wird temporär der Bundeslandname (`bname`) mit gespeichert (genauso beim `ort`).

AUF-04-1 Erstellen Sie für die Tabellen entsprechende create table bzw. alter table Befehle und notieren Sie diese.

Notiz:

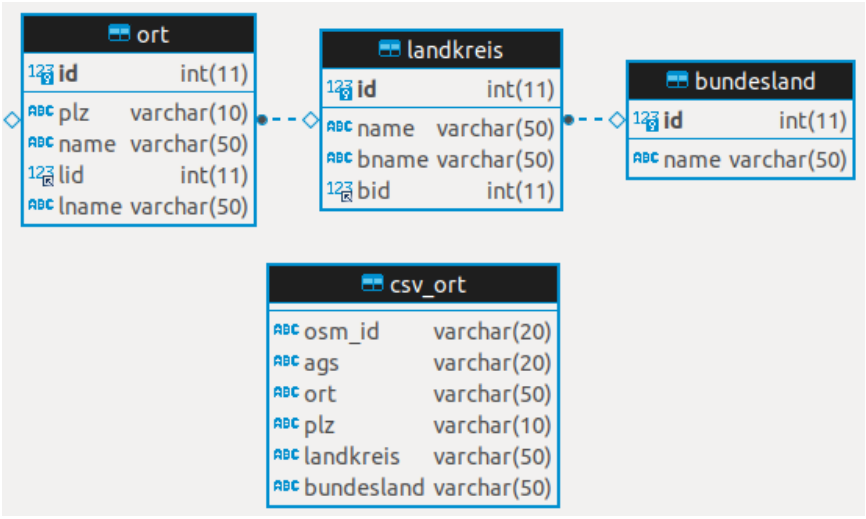

4. **Bundesländer anzeigen und einfügen**
   Da auf die Spalte `bundesland` ein Index gelegt worden ist, wird dieser automatisch genutzt und somit ist die Ausgabe sortiert.

```
select distinct bundesland from csv_ort;
+------------------------+
| bundesland             |
+------------------------+
| Baden-Württemberg      |
| Bayern                 |
| Berlin                 |
| Brandenburg            |
| Bremen                 |
| Hamburg                |
| Hessen                 |
| Mecklenburg-Vorpommern |
| Niedersachsen          |
| Nordrhein-Westfalen    |
| Rheinland-Pfalz        |
| Saarland               |
| Sachsen                |
| Sachsen-Anhalt         |
| Schleswig-Holstein     |
| Thüringen              |
+------------------------+

INSERT INTO bundesland
       (name) select distinct bundesland from csv_ort;

Query OK, 16 rows affected (0.007 sec)
Records: 16  Duplicates: 0  Warnings: 0
```

```
select * from bundesland;
+----+------------------------+
| id | name                   |
+----+------------------------+
|  1 | Baden-Württemberg      |
|  2 | Bayern                 |
|  3 | Berlin                 |
|  4 | Brandenburg            |
|  5 | Bremen                 |
|  6 | Hamburg                |
|  7 | Hessen                 |
|  8 | Mecklenburg-Vorpommern |
|  9 | Niedersachsen          |
| 10 | Nordrhein-Westfalen    |
| 11 | Rheinland-Pfalz        |
| 12 | Saarland               |
| 13 | Sachsen                |
| 14 | Sachsen-Anhalt         |
| 15 | Schleswig-Holstein     |
| 16 | Thüringen              |
+----+------------------------+
```

Notiz:

5. **Landkreise einfügen**[1]

```
INSERT INTO landkreis (name,bname)
   select
      distinct landkreis,bundesland
      from csv_ort
      where landkreis > ''
      order by landkreis;

# bid anpassen
update landkreis set bid=(select id from bundesland where bname=name);

# landkreise anzeigen
select * from landkreis limit 10;
+----+--------------------------+---------------------+------+
| id | name                     | bname               | bid  |
+----+--------------------------+---------------------+------+
|  1 | Alb-Donau-Kreis          | Baden-Württemberg   |    1 |
|  2 | Altmarkkreis Salzwedel   | Sachsen-Anhalt      |   14 |
|  3 | Bodenseekreis            | Baden-Württemberg   |    1 |
|  4 | Burgenlandkreis          | Sachsen-Anhalt      |   14 |
|  5 | Donnersbergkreis         | Rheinland-Pfalz     |   11 |
|  6 | Eifelkreis Bitburg-Prüm  | Rheinland-Pfalz     |   11 |
|  7 | Ennepe-Ruhr-Kreis        | Nordrhein-Westfalen |   10 |
|  8 | Enzkreis                 | Baden-Württemberg   |    1 |
|  9 | Erzgebirgskreis          | Sachsen             |   13 |
| 10 | Hochsauerlandkreis       | Nordrhein-Westfalen |   10 |
+----+--------------------------+---------------------+------+
```

Notiz:

1 Achtung: kreisfreie Städte wie z. B. München haben keinen Landkreis!

6. **Orte einfügen**

```
# alte Orte löschen
SET @OLD_FOREIGN_KEY_CHECKS=@@FOREIGN_KEY_CHECKS, FOREIGN_KEY_CHECKS=0;
SET @OLD_UNIQUE_CHECKS=@@UNIQUE_CHECKS, UNIQUE_CHECKS=0;
TRUNCATE ort;

INSERT INTO ort (plz,name,lname)
   select
      plz, ort,landkreis
      from csv_ort
      order by ort;

# lid anpassen
update ort set lid=(select id from landkreis where lname=name);

# Orte anzeigen
select * from ort limit 10;
+----+-------+--------+------+--------------------------+
| id | plz   | name   | lid  | lname                    |
+----+-------+--------+------+--------------------------+
|  1 | 78267 | Aach   |  143 | Landkreis Konstanz       |
|  2 | 54298 | Aach   |  235 | Landkreis Trier-Saarburg |
|  3 | 52080 | Aachen |  286 | Städteregion Aachen      |
|  4 | 52078 | Aachen |  286 | Städteregion Aachen      |
|  5 | 52076 | Aachen |  286 | Städteregion Aachen      |
|  6 | 52074 | Aachen |  286 | Städteregion Aachen      |
|  7 | 52072 | Aachen |  286 | Städteregion Aachen      |
|  8 | 52070 | Aachen |  286 | Städteregion Aachen      |
|  9 | 52068 | Aachen |  286 | Städteregion Aachen      |
| 10 | 52066 | Aachen |  286 | Städteregion Aachen      |
+----+-------+--------+------+--------------------------+
```

AUF-04-2 Warum müssen vor dem Befehl `TRUNCATE ort` die Checks ausgeschaltet werden?

Notiz:

7. **Aufräumen, Mitarbeiter anpassen und FKs setzen**

```
ALTER table ort drop column lname;
ALTER table landkreis drop column bname;
DROP table csv_ort;

# Mitarbeiter: oid neu setzen
update mitarbeiter set oid=(
   select id from ort where plz='85662' AND name='Hohenbrunn')
   where id in (8,9);
update mitarbeiter set oid=(
   select id from ort where plz='85653' AND name='Aying')
   where id in (6,7);
update mitarbeiter set oid=(
   select id from ort where plz='82061' AND name='Neuried')
   where id in (4,5);
update mitarbeiter set oid=(
   select id from ort where plz='85521' AND name='Hohenbrunn')
   where id=3;
update mitarbeiter set oid=(
   select id from ort where plz='85653' AND name='Aying')
   where id=2;
update mitarbeiter set oid=(
   select id from ort where plz='85609' AND name='Aschheim')
   where id=1;

# FKs
ALTER table ort ADD CONSTRAINT fk_ort_landkreis
      Foreign key (lid) References landkreis (id);

ALTER table landkreis ADD CONSTRAINT fk_landkreis_bundesland
      Foreign key (bid) References bundesland (id);
```

Notiz:

8. **Prüfen...**

```
desc ort;
+-------+-------------+------+-----+---------+----------------+
| Field | Type        | Null | Key | Default | Extra          |
+-------+-------------+------+-----+---------+----------------+
| id    | int(11)     | NO   | PRI | NULL    | auto_increment |
| plz   | varchar(10) | YES  |     | NULL    |                |
| name  | varchar(50) | YES  |     | NULL    |                |
| lid   | int(11)     | YES  | MUL | NULL    |                |
+-------+-------------+------+-----+---------+----------------+

desc landkreis;
+-------+-------------+------+-----+---------+----------------+
| Field | Type        | Null | Key | Default | Extra          |
+-------+-------------+------+-----+---------+----------------+
| id    | int(11)     | NO   | PRI | NULL    | auto_increment |
| name  | varchar(50) | YES  |     | NULL    |                |
| bid   | int(11)     | YES  | MUL | NULL    |                |
+-------+-------------+------+-----+---------+----------------+

select m.name,m.vorname, o.plz, o.name
       from mitarbeiter m left join ort o on m.oid=o.id;
+--------+----------+-------+------------+
| name   | vorname  | plz   | name       |
+--------+----------+-------+------------+
| Walker | Jonny    | 85609 | Aschheim   |
| Schlau | Susi     | 85653 | Aying      |
| Ratlos | Rudi     | 85521 | Hohenbrunn |
| Keller | Brigitte | 82061 | Neuried    |
| Keller | Josef    | 82061 | Neuried    |
| Huber  | Sepp     | 85653 | Aying      |
| Meier  | Siglinde | 85653 | Aying      |
| Mair   | Hans     | 85662 | Hohenbrunn |
| Maier  | Peter    | 85662 | Hohenbrunn |
+--------+----------+-------+------------+
```

Sie sehen, mit SQL solch einen Datenimport zu machen, ist nicht immer ganz so einfach. Verwendet man dagegen eine Programmiersprache wie Java, ist dies deutlich einfacher.

AUF-04-3 Führen Sie schrittweise den Import selber durch!

Notiz:

Problem: kreisfreie Städte

Bei dem jetzigen Datenmodell gibt es ein Problem bei kreisfreien Städten, da diese keinem Landkreis zugeordnet sind.

```
select * from ort where lid is null limit 5;
+-----+-------+---------------+------+
| id  | plz   | name          | lid  |
+-----+-------+---------------+------+
| 287 | 92224 | Amberg        | NULL |
| 331 | 91522 | Ansbach       | NULL |
| 393 | 63739 | Aschaffenburg | NULL |
| 394 | 63741 | Aschaffenburg | NULL |
| 395 | 63743 | Aschaffenburg | NULL |
+-----+-------+---------------+------+
```

AUF-04-4 Somit lässt sich nicht ermitteln, in welchem Bundesland die Stadt liegt. Überlegen Sie sich dazu eine Lösung und setzen Sie diese um.

Notiz: