

Базы данных и язык SQL

Егор Суворов

Курс «Парадигмы и языки программирования», подгруппа 3

Среда, 16 ноября года

План занятия

1 Основы основ

- Текстовые файлы, БД и СУБД
- Реляционные СУБД и простой SQL
- Использование СУБД
- Немного практики

2 Запросы посложнее

- Группировка строк
- Подзапросы
- Соединения
- Объединения результатов запросов

1 Основы основ

- Текстовые файлы, БД и СУБД
- Реляционные СУБД и простой SQL
- Использование СУБД
- Немного практики

2 Запросы посложнее

- Группировка строк
- Подзапросы
- Соединения
- Объединения результатов запросов

Постановка задачи

- Пусть мы пишем приложения для учёта товаров в магазине.
- Надо знать:
 - 1 Какой товар есть на складе и витринах.
 - 2 Где он лежит.
 - 3 По какой цене товар закуплен (могут быть разные партии).
 - 4 По какой цене товар сейчас продаётся.
 - 5 Какие покупки были сделаны (что куплено вместе, на какую сумму, в какое время).
- Возможные события:
 - 1 Приехала поставка со склада.
 - 2 Касса пробила чек — совершена покупка.
- Надо, чтобы приложение сохраняло состояние между перезапусками.
- Вопрос: как это сделать?

Вариант с файлами

- Создаём кучу внутренних структур для хранения объектов.
- При выходе из приложения пишем их в каком-то формате на диск, при запуске — считываем.

Проблемы:

Вариант с файлами

- Создаём кучу внутренних структур для хранения объектов.
- При выходе из приложения пишем их в каком-то формате на диск, при запуске — считываем.

Проблемы:

- На запуск и выход требуется существенное время (записать много данных).
- Если пропало питание, мы потеряли данные.

Решения:

Вариант с файлами

- Создаём кучу внутренних структур для хранения объектов.
- При выходе из приложения пишем их в каком-то формате на диск, при запуске — считываем.

Проблемы:

- На запуск и выход требуется существенное время (записать много данных).
- Если пропало питание, мы потеряли данные.

Решения:

- Меняем формат файла, чтобы можно было обновлять только изменившиеся кусочки.
- Храним структуры и объекты в разных маленьких файлах, чтобы изменения обрабатывала файловая система, а не мы.

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Возможные решения:

- ① Каждая хранит данные независимо, а после закрытия мы склеиваем данные вместе:

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Возможные решения:

- ① Каждая хранит данные независимо, а после закрытия мы склеиваем данные вместе:
 - Несложно пишется и сложно вызвать цепную реакцию из ошибок — ломается только в момент склейки.
 - Так раньше работали банки («ваш перевод будет обработан в течение X дней»).
 - Нет доступа к данным в реальном времени.

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Возможные решения:

- ② Дать общий доступ ко всем файлам со всех компьютеров:

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Возможные решения:

- ② Дать общий доступ ко всем файлам со всех компьютеров:
 - Появляется конкуренция за доступ и race condition: нельзя, чтобы две программы одновременно работали с одним файлом.
 - Если изменение затрагивает несколько файлов, то надо их все захватывать; не все сетевые ФС так умеют.

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Возможные решения:

- ③ Написать программу-сервер, которая как-то хранит данные на одном компьютере и обрабатывает сетевые запросы от клиентов:

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Возможные решения:

- ➊ Написать программу-сервер, которая как-то хранит данные на одном компьютере и обрабатывает сетевые запросы от клиентов:
 - Получили абстракцию «хранилище данных».
 - Хранилище инкапсулирует то, как именно данные хранятся (хоть в памяти, хоть на десяти серверах распределённо).

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Общие проблемы:

Усложнение

- А теперь у нас десять касс и два компьютера в разных концах склада.
- Одной программы теперь недостаточно, надо несколько.

Общие проблемы:

- Хранилище сильно завязано на то, какие именно данные оно хранит: формат хранения на диске, протокол, внутренние структуры...
- Не очень много кода в хранилище действительно хочет знать о структуре данных что-то подробнее «число или строка».
- Для любого взаимодействия с хранилищем требуется писать своё новое приложение с поддержкой протокола.

СУБД

- Система управления базами данных (СУБД) — это сервис, который умеет хранить данные произвольной структуры (в определённых рамках, конечно, не совсем бессистемные).
- База данных — это описание данных и их структуры, которые хранятся в СУБД.
- СУБД обычно делят на два вида в зависимости от того, как они структурируют данные: реляционные (relational) и нереляционные (non-relational или NoSQL).
- Реляционные — это классика (существуют с 80-х годов), их и будем изучать.
- Нереляционные примерно того же возраста, но вошли в тренд только в последние лет десять.
- Примеры реляционных: MySQL, MariaDB, Oracle, MS SQL, Sqlite.
- Примеры нереляционных: MongoDB, Redis, Memcached, Cassandra.

Реляционные СУБД на практике

- СУБД хранит одну или несколько независимых БД (баз данных).
- Каждая БД — это набор таблиц, которые содержат данные.
- Таблица имеет фиксированный набор столбцов с названиями и типами.
- Фиксированный в каждый момент времени; вообще столбцы можно добавлять, менять, удалять, хоть это и сложные для СУБД операции.
- В таблице лежит неупорядоченный набор строк с данными.
- На столбцы (или их группы) могут накладываться дополнительные ограничения (например, «все значения в столбце различны»).
- Обычно запросы к реляционным СУБД формулируются на декларативном языке SQL (Structured Query Language).

Реляционная алгебра

Математическая модель происходящего в реляционных СУБД:

- Таблица называется *отношением* (relation, отсюда relational database).
- Есть операции над таблицами (образующие алгебру). Например, «выбрать какие-то строчки из таблицы».
- Обычно СУБД поддерживают гораздо более крутые и странные операции, чем в реляционной алгебре.
- Больше слова «реляционная алгебра» вам наверняка не пригодятся.

Классическая шутка

Three database admins walked into a NoSQL bar.
A little while later they walked out because they
could not find a table.

Типы данных

Смотрим на таблицу `Country`:

- `INTEGER` — целое число (размер варьируется от СУБД к СУБД, как и название).
- `REAL` — вещественное число с плавающей запятой.
- `VARCHAR(45)` — строка произвольной длины, но не длиннее 45 символов¹. Если не влезает — поведение зависит от СУБД.

Вообще говоря, конкретно в SQLite значения в столбце могут иметь тип, не совпадающий со столбцом, но об этом лучше не думать.

За кадром остались типы:

- `BLOB` — бинарные данные любой длины.
- `TEXT` — строка произвольной длины без ограничений.
- `CHAR(10)` — строка фиксированной длины (может работать быстрее).

¹ А сколько символов занимает буква «ш»? А в какой кодировке?

Прочие типы данных

В каждой СУБД свои типы, они могут отличаться по поведению даже просто при разных настройках внутри одной базы данных. Но обычно они называются приблизительно так:

- DECIMAL(10, 5) — вещественное число с фиксированной запятой.
- Вариации на тему целых чисел: SMALLINT, MEDIUMINT, ...
- FLOAT — альтернатива DOUBLE.
- DATE, TIME, DATETIME, TIMESTAMP и вариации для хранения дат².

Мораль двух слайдов: сразу сказать, какой тип «правильный» в конкретной ситуации нельзя, надо хорошо понимать предметную область и СУБД, с которой вы работаете. Но для своих проектов по умолчанию можно ограничиться теми типами, что проще называются.

²Правильная работа с датами — тема отдельной лекции: 1, 2

Демонстрация SQL-запросов

- Запросы отделяются между собой точкой с запятой.
- Иногда интерфейс к СУБД не умеет делать несколько запросов одновременно и тогда точка с запятой не нужна.
- Комментарии — либо два дефиса в начале строки, либо /* ... */
- Результат запроса SELECT — тоже таблица, полученная из исходной.
- Наборы строк и столбцов в результате SELECT могут разительно отличаться от исходной.
- Можно фильтровать строки по условиям.
- Можно попросить не строки, а какую-то статистику.
- Если вы в SQL что-то написали, оно практически всегда либо упадёт при компиляции, либо как-то отработает на любых значениях.

LIMIT и OFFSET

- Порядок строк в таблицах и результате работы SELECT не определён.
- Но его можно явно задать при помощи ORDER BY, который сравнивает поля лексикографически в указанном порядке.
- Важно задавать ORDER BY так, чтобы он всегда отличал две строки. Этого можно добиться, только если мы знаем, какие наборы столбцов всегда отличаются.
- Другая стандартная проблема: пусть мы подгружаем бесконечную ленту новостей запросом LIMIT 10 OFFSET already_loaded.

LIMIT и OFFSET

- Порядок строк в таблицах и результате работы SELECT не определён.
- Но его можно явно задать при помощи ORDER BY, который сравнивает поля лексикографически в указанном порядке.
- Важно задавать ORDER BY так, чтобы он всегда отличал две строки. Этого можно добиться, только если мы знаем, какие наборы столбцов всегда отличаются.
- Другая стандартная проблема: пусть мы подгружаем бесконечную ленту новостей запросом LIMIT 10 OFFSET already_loaded.
- Новости в ленте могут добавляться и удаляться, и номера строк даже в идеально отсортированной таблице постоянно меняются.

Мораль: не стоит надеяться на номера строк, LIMIT и OFFSET обычно возникают только при выборке «топ-10».

Правильное решение задачи с лентой:

LIMIT и OFFSET

- Порядок строк в таблицах и результате работы SELECT не определён.
- Но его можно явно задать при помощи ORDER BY, который сравнивает поля лексикографически в указанном порядке.
- Важно задавать ORDER BY так, чтобы он всегда отличал две строки. Этого можно добиться, только если мы знаем, какие наборы столбцов всегда отличаются.
- Другая стандартная проблема: пусть мы подгружаем бесконечную ленту новостей запросом LIMIT 10 OFFSET already_loaded.
- Новости в ленте могут добавляться и удаляться, и номера строк даже в идеально отсортированной таблице постоянно меняются.

Мораль: не стоит надеяться на номера строк, LIMIT и OFFSET обычно возникают только при выборке «топ-10».

Правильное решение задачи с лентой: «верни топ-10 запросов после такой-то новости из ленты».

DELETE и INSERT

Удаление значений:

- `DELETE FROM Country` удалит **все** строки и не почешется.
- Надо писать `DELETE FROM Country WHERE ...`
- По-хорошему перед `DELETE` стоит сделать `SELECT` и посмотреть.

Добавление значений:

- После слова `VALUES` можно написать несколько кортежей со значениями, но надо знать точный порядок столбцов в таблице.
- На практике столбцы иногда (не часто, но иногда) меняются, добавляются и удаляются, поэтому всегда следует писать явно, каким столбцам что соответствует.
- При вставке может возникнуть ошибка, если на каком-то столбце были ограничения

Остальные запросы

- Также бывают запросы CREATE TABLE, ALTER TABLE, DROP TABLE для работы с таблицами.
- Несмотря на наличие стандартов языка SQL, каждая база дополняет его по-своему, из-за чего получается множество несовместимыхialectов.
- Самые базовые команды (только что были) везде работают примерно одинаково (за исключением неоднозначных ситуаций).

1 Основы основ

- Текстовые файлы, БД и СУБД
- Реляционные СУБД и простой SQL
- Использование СУБД
- Немного практики

2 Запросы посложнее

- Группировка строк
- Подзапросы
- Соединения
- Объединения результатов запросов

Где и зачем

СУБД используются практически везде:

- Если данных или клиентов (которые запрашивают/меняют данные) будет очень много, то нам не надо изобретать велосипед и писать своё масштабируемое хранилище:
 - ① Обычно одна СУБД обслуживает сразу несколько приложений.
 - ② Можно создавать разных пользователей с разными правами.
 - ③ Можно прозрачно для приложений делать бэкапы или хранить данные на десяти серверах.

Где и зачем

СУБД используются практически везде:

- Если мы просто пишем приложение с какой-то нетривиальной схемой:
 - ❶ Очень чётко отделяются данные от их обработки.
 - ❷ SQL все знают (в отличие от логики программы), легко делать запросы к БД, зная только схему, и не зная ничего про приложение.
 - ❸ SQL мощнее и читается лучше циклов `for` и `list comprehension`, которые ещё и не во всех языках есть.
 - ❹ Не надо думать про хранение данных.

Где и зачем

СУБД используются практически везде:

- Если мы data scientist и/или хотим активно проверять гипотезы и много/просто работать с данными:
 - ❶ Удобно, когда все данные лежат в БД с известным интерфейсом (SQL).
 - ❷ Не надо писать никакой код и ни с чем интегрироваться, чтобы выполнить запрос.
 - ❸ Не получится набагать в коде в обработке крайних случаев³

³Даже в SQL можно посадить сложный баг

В чём минусы

- Мы отдаём контроль за скоростью выполнения и потреблением памяти в руки СУБД (как и при любой абстракции). Это обычно приемлемый компромисс.
- Приложение сложнее запустить: нужно настроить СУБД, что обычно занимает несколько шагов. В нестандартных ситуациях — больше.
- Иногда приложение требует слишком хитрую настройку СУБД (например, для корректной работы с не-латиницей и датами).
- Многие инструменты заточены под промышленные решения и имеют слишком много рычажков и кнопок для простых целей.

Встраиваемые СУБД

- Самая известная встраиваемая СУБД — sqlite.
- Предназначена не для сетевого доступа, а для использования в рамках одной конкретной программы.
- Её можно просто вкомпилировать в своё приложение, не требуется никакой настройки.
- sqlite хранит каждую БД в отдельном файле определённого формата (последний — sqlite3).
- Формат sqlite3 один на все приложения, можно даже залезть в чужие БД и посмотреть.
- Занимает мало места в скомпилиированном приложении.
- Используется [во многих приложениях](#): под Android, в Firefox, в Chrome, в клиенте Dropbox⁴...

⁴ ищите файлы .db, .sqlite, .sqlite3

Анонс домашнего задания

- Вам будет выдан файл с SQL-запросами, которые создают таблицы со странами (структуру разберём) и заполняют их данными.
- Вам нужно написать несколько SQL-запросов SELECT, которые что-то вычисляют.
- Тестировать можно на созданных тестовых данных.
- Как именно тестировать — сейчас покажу.

Консольная утилита

- Называется sqlite3. Это просто программа, которая умеет выполнять SQL-запросы на БД sqlite.
- По умолчанию создаёт пустую БД в памяти.
- Можно попросить открыть существующую БД в файле (или создать новый файл).
- При помощи перенаправления может выполнять SQL из файла.
- SQL-запрос должен заканчиваться точкой с запятой.

Графическая утилита

- Я выбрал DB Browser for SQLite.
- Иногда проще смотреть на таблице в графической оболочке, чем в консоли.
- Может открывать файлы с БД, все изменения идут в памяти.
- Можно откатывать изменения кнопкой «Revert Changes» до последнего сохранения.
- Можно сохранять изменения в файл кнопкой «Write Changes».
- Показывает таблицы, их структура, позволяет выполнять произвольные запросы.

Python

```
with sqlite3.Connection("literacy.sqlite3") as db:  
    cursor = db.execute("SELECT * FROM Country LIMIT 3")  
    print(cursor.description)  
    print(list(cursor))  
    print(list(cursor)) # Что-нибудь выведет?
```

- Терминология очень похожа во всех языках и СУБД.
- Обычно в языке есть стандартный интерфейс общения с любыми СУБД. А *драйвер* СУБД реализует этот интерфейс в языке.
- Сначала мы устанавливаем *соединение* с СУБД.
- Результатом запроса является *курсор* — это такой итератор по строчкам запроса.
- Что возвращают запросы, кроме SELECT — зависит от СУБД.
- Иногда считается, что не запрос возвращает курсор, а надо сначала создать курсор, а потом в нём выполнить запрос.

Упражнения

- ➊ Скачайте файл `literacy.sql`.
- ➋ Выберите имя для файла, где у вас будет лежать БД для тестов (например, `literacy.sqlite3`).
- ➌ Выполните запросы из `literacy.sql`:

```
sqlite3 literacy.sqlite3 < literacy.sql
```

Каждый раз, когда вы будете выполнять команды из `literacy.sql`, таблицы будут полностью пересозданы. Не бойтесь что-то сломать.

- ➍ Выполните SQL-запросы (либо в командной строке, либо в GUI):
 - ➊ Всю информацию по всем странам.
 - ➋ Первые десять стран (если сортировать по названию).
 - ➌ Средние население и площадь страны.
 - ➍ Площадь и население Франции.
 - ➎ Количество французских территорий и их суммарную площадь и население.

NULL

Также есть специальное значение NULL, которое может лежать в любой колонке, если только на ней нет ограничения NOT NULL. Может обозначать:

- Отсутствие каких-либо данных (неизвестно население страны).
- Неопределённый результат вычисления (среднее значение пустого множества, деление на ноль).
- Что угодно ещё по желанию программиста.

Возникающая проблема: нет одного объяснения, как NULL себя ведёт в разных запросах.

- Если считать, что NULL распространяется как NaN (Not a Number), т.е. любое вычисление с NULL даёт NULL, то сложно писать запросы в ситуации, где наличие NULL — норма.
- Если NULL просто игнорировать, то про него легко забыть (так часто и делают); а он может где-то требовать специальной обработки.

Демонстрация NULL

- Разные функции обрабатывает NULL по-разному, общая цель — наиболее консистентное и адекватное поведение.
- Обычно в агрегирующих функциях игнорируется.
- Если вы пишете чуть-чуть несимметричный код (вроде `SUM(a) / COUNT(*)`), могут быть последствия.
- Очень легко забыть и получить какой-то правдоподобный, но неверный результат (особенно в соединениях — будут дальше).

SQL-инъекции

Пусть есть таблица с полями: владелец текста, его название, содержимое. Код для доступа к базе, выполняется на сервере:

```
with sqlite3.Connection("sql-injection.sqlite3") as db:  
    key = input('Text key: ')  
    cursor = db.execute("""SELECT * FROM Text  
        WHERE owner='user' AND key='{}'""".  
        format(key))  
    print(list(cursor))
```

В чём проблема?

SQL-инъекции

Пусть есть таблица с полями: владелец текста, его название, содержимое. Код для доступа к базе, выполняется на сервере:

```
with sqlite3.Connection("sql-injection.sqlite3") as db:  
    key = input('Text key: ')  
    cursor = db.execute("""SELECT * FROM Text  
        WHERE owner='user' AND key='{}'""".  
        format(key))  
    print(list(cursor))
```

В чём проблема?

Значение: key1

Было: SELECT ... WHERE owner='user' AND key='{}'

Стало: SELECT ... WHERE owner='user' AND key='key1'

SQL-инъекции

Пусть есть таблица с полями: владелец текста, его название, содержимое. Код для доступа к базе, выполняется на сервере:

```
with sqlite3.Connection("sql-injection.sqlite3") as db:  
    key = input('Text key: ')  
    cursor = db.execute("""SELECT * FROM Text  
        WHERE owner='user' AND key='{}'""".  
        format(key))  
    print(list(cursor))
```

К коллайдеру! Упс.

SQL-инъекции

Пусть есть таблица с полями: владелец текста, его название, содержимое. Код для доступа к базе, выполняется на сервере:

```
with sqlite3.Connection("sql-injection.sqlite3") as db:  
    key = input('Text key: ')  
    cursor = db.execute("""SELECT * FROM Text  
        WHERE owner='user' AND key='{}'""".  
        format(key))  
    print(list(cursor))
```

К коллайдеру!

Значение: ' OR ''='

Было: SELECT ... WHERE owner='user' AND key='{}'

Стало: SELECT ... WHERE owner='user' AND key="" OR ""=""

Упс.

Классический комикс



А как правильно?

```
with sqlite3.Connection("sql-injection.sqlite3") as db:  
    key = input('Text key: ')  
    cursor = db.execute("SELECT * FROM Text WHERE owner='user' AND key=?")  
    print(list(cursor))
```

Теперь драйвер базы данных знает, что `key` — это значение от пользователя, которое надо заэкрантировать:

Значение: ' OR ''='

Было: ... WHERE owner='user' AND key=?

Стало: ... WHERE owner='user' AND key='\'' OR '\'\''=\''

Независимо от того, какой код мы напишем, SQL-инъекции не случится.

Мораль: никогда не собираите SQL-запрос руками из переменных.

1 Основы основ

- Текстовые файлы, БД и СУБД
- Реляционные СУБД и простой SQL
- Использование СУБД
- Немного практики

2 Запросы посложнее

- Группировка строк
- Подзапросы
- Соединения
- Объединения результатов запросов

GROUP BY

- Полезно, когда мы хотим посчитать какую-то статистику по подмножествам строк.
- Каждая агрегирующая функция работает только внутри группы.
- Например, суммарное население стран с разным политическим строем.
- Можно группировать по нескольким полям.
- Условие WHERE применяется до группировки.
- ORDER BY применяется после (очевидно, так как группировка от порядка не зависит).
- В SELECT можно использовать только агрегирующие функции и колонки, по которым сделана группировка (иначе неясно, из какой строки выбирать). Некоторые СУБД ругаются, некоторые делают что-то.
- Можно дополнительно отфильтровать результаты после группировки при помощи HAVING.

Упражнения

Посчитайте:

- ① Среднюю площадь страны в зависимости от формы правления.
- ② Средний корень площади страны в зависимости от формы правления.
- ③ Количество стран с площадью порядка миллиона, порядка двух миллионов, и так далее.

Подзапросы-1

- ①
 - Задача: хотим для города найти население страны, в которой он расположен.
 - В таблице городов есть только код страны, без населения.
 - Можно сделать подзапрос в условии WHERE.
- ②
 - Задача: хотим найти средний уровень самой грамотной страны по годам.
 - Надо две агрегатных функции: сначала группируем по годам (чтобы найти победителя), а потом берём среднее.
 - Можно сделать подзапрос в FROM (ведь результат SELECT — тоже таблица, которую можно назвать).

Подзапросы-2

- Задача: хотим вывести информацию по странам плюс население самого большого города.
- Эта информация лежит в двух разных таблицах.
- SQL позволяет делать SELECT FROM сразу из нескольких таблиц (получается декартово произведение).
- Можно взять декартово произведение городов и стран, оставить только соответствующие, а по оставшимся взять агрегирующую функцию.
- Если имена колонок в разных таблицах совпадают, надо явно указывать, к какой мы обращаемся.
- Вообще лучше всегда явно указывать, из какой таблицы мы берём колонку, если таблиц несколько.

Такого sorta выборки происходят очень часто, в реляционной алгебре они зовутся «соединениями» (join).

Соединения

- Можно считать синтаксическим сахаром для взятия подмножества декартова произведения.
- Лучше отражает суть происходящего и проще читается.
- После ON может быть произвольное условие (это круче, чем в реляционной алгебре).
- Обычно там ставят условие «номер страны в первой таблице равен номеру страны во второй таблице».

Ключи и соединения-1

- Обычно сущностей в базе много и они как-то связаны отношениями («каждый город лежит ровно в одной стране»).
- Не хочется дублировать информацию в разных таблицах (место занимает, изменять сложно).
- Поэтому информация о стране/городе отдельно.
- А запрос «получи объект по вот этому отношению» возникает.
- Так как свойства объектов часто меняются, то обычно каждому объекту выдают *первичный ключ*, по которому его можно опознать. Обычно это просто какое-то число (возможно, с автоинкрементом).

Ключи и соединения-2

- Тогда связи вроде «в какой стране лежит город» — это просто столбец «номер страны» в таблице с городом.
- Такой столбец называют *внешним ключом*.
- Это даже можно отразить в структуре таблицы (`REFERENCES`).
- И ещё можно указать, что делать при удалении того объекта, куда мы ссылаемся (`ON DELETE CASCADE`).

Упражнения

- ① Вывести для каждой страны максимальный уровень её грамотности за все годы.
- ② Вывести для каждой страны номер города-столицы (см. таблицу Capital).
- ③ Вывести для каждой страны название города-столицы (потребуется два JOIN).

Соединения, NULL, отсутствие значений

- ➊ Посчитаем количество стран (239).
 - ➋ Теперь для каждой страны посчитаем количество городов.
 - ➌ Теперь посмотрим, сколько строк получили в результате — 232.
- А всё потому что есть страны, в которых городов нет — про них в таблице City просто нет информации.
 - И соединение не поможет — страна без городов отфильтруется.
 - Но есть LEFT (OUTER) JOIN — он обязуется добавить в соединение все строчки из «левой» таблицы (а если не нашлось соответствующих строк, то поля второй в строчке соединения будут NULL).
 - С ним надо быть осторожным — потому что теперь в строчках соединения могут оказаться NULL, которые, скорее всего, не надо учитывать (`COUNT(*)`, например, их учтёт).
 - Ещё бывают аналогичные RIGHT JOIN и FULL JOIN (SQLite их не поддерживает).

Классическая шутка



lol.browserling.com

An SQL query walks into a bar and sees two tables.
He walks up to them and says "Can I join you?"

UNION

- Хотим вывести названия всех географических объектов из БД.
- Делаем два (или больше) SELECT с одинаковым количеством столбцов в результате.
- Если объединяем их через UNION — то в результате не будет одинаковых строк вообще (даже если они были внутри одного SELECT).
- Если объединяем их через UNION ALL — то просто все результаты объединяются вместе.

На практике:

- Я ни разу не встречал.
- Может потребоваться, если в БД есть похожие таблицы (например, UsersUS и UsersEU).