МГТУ
им. Н. Э. Баумана
ТЕХНОПАРК
Mail.Ru Group

# Прикладной Python

Лекция №6

Владимир
Денисов

# Базы данных

- Базовые понятия реляционных БД
- Проектирование БД
- SQL. Основные операции: SELECT, INSERT, UPDATE, DELETE, JOIN
- Индексы
- EXPLAIN
- NoSQL

# Где хранить данные?

- На клиенте
  - Cookie (4кб)
  - Web Storage
- На сервере
  - В памяти
  - На диске
  - На диске и в памяти

# Терминология

- **БД** - Взаимосвязанные данные специальным образом хранящиеся на каком-либо носителе
- **СУБД** – Программный комплекс обеспечивающий работу с данными в БД

# Предназначение СУБД

- Управление данными на дисках и в оперативной памяти
- Журнализация, резервное копирование
- Предоставление интерфейсов взаимодействия с БД
- Предоставление механизма транзакций

# Реляционная модель данных

- Таблица - отношение, relation
- Строка - кортеж, tuple
- Столбец - атрибут, column

# Таблица пользователей

| id | first_name | last_name | username |
|---|---|---|---|
| 26479 | Дмитрий | Васильев | dmitry.vasilyev |
| 26477 | Кирилл | Занадворов | k.zanadvorov |
| 26475 | Аникеев | Алексей | a.anikeev |
| 26473 | Руслан | Сабитов | r.sabitov |
| 26471 | Полина | Ольхова | p.olkhova |

# Терминологи
# ия

- **Первиичный ключ** (*primary key*) — в реляционной модели данных один из потенциальных ключей отношения, выбранный в качестве основного ключа (или ключа по умолчанию).

  Если в отношении имеется единственный потенциальный ключ, он является и первичным ключом. Если потенциальных ключей несколько, один из них выбирается в качестве первичного, а другие называют «альтернативными».

# Терминология

- **Внешний ключ** — это столбец или комбинация столбцов, значения которых соответствуют Первичному ключу в другой таблице. Связь между двумя таблицами задается через соответствие первичного **ключа** в одной из таблиц **внешнему** ключу во второй.

# Виды связей в реляционной БД

Связь **один к одному** образуется, когда ключевой столбец (идентификатор) присутствует в другой таблице, в которой тоже является ключом либо свойствами столбца задана его уникальность (одно и тоже значение не может повторяться в разных строках).

Связи **один ко многим** одной записи первой таблицы соответствует несколько записей в другой таблице.

Если нескольким записям из одной таблицы соответствует несколько записей из другой. таблицы, то такая связь называется «**многие ко**

# Примеры

| Color | |
|---|---|
| Key | Name |
| 1 | Black |
| 2 | Pink |

| Car | | | |
|---|---|---|---|
| Key | Model | Color | Year |
| 1 | Toyota Camry | 1 | 2010 |
| 2 | Audi A4 | 2 | 2013 |
| 3 | Honda Civic | 2 | 2013 |

# Примеры

| Cousine | | |
|---|---|---|
| Key | Name | Type |
| 1 | Baked fish | Main Course |
| 2 | Pork Chops | Main Course |

| Ingredient | |
|---|---|
| Key | Name |
| 1 | Pork |
| 2 | Lamb |
| 3 | Salmon |

# Пример

| Cousine | | |
|---|---|---|
| Key | Name | Type |
| 1 | Baked fish | Main Course |
| 2 | Pork Chops | Main Course |

| Ingredient | |
|---|---|
| Key | Name |
| 1 | Pork |
| 2 | Lamb |
| 3 | Salmon |

| CousineIngredient | |
|---|---|
| CousineKey | IngredientKey |
| 1 | 3 |
| 2 | 1 |

# Структура SQL запроса SELECT

```
SELECT
   [DISTINCT | DISTINCTROW | ALL]
   select_expression,...
FROM table_references
[WHERE where_definition]
[GROUP BY {unsigned_integer | col_name | formula}]
[HAVING where_definition]
[ORDER BY {unsigned_integer | col_name | formula} [ASC | DESC],
...]
```

# Операции SQL: SELECT

```
1.  SELECT * FROM users WHERE age > 10;
2.  SELECT * FROM users WHERE name = 'masha';
3.  SELECT MAX(age) FROM users;

4.  SELECT id, name, LENGTH(name) AS len
5.  FROM users
6.  WHERE email LIKE '%@mail.ru' AND age > 10
7.  ORDER BY name DESC
8.  LIMIT 10 OFFSET 15;
```

Дока по встроенным методам в MySQL
https://dev.mysql.com/doc/refman/8.0/en/string-functions.html

# Агрегация

```
1.  SELECT first_name, count(id) as cnt
2.  FROM users_user
3.  WHERE first_name
4.  LIKE "%дим%"
5.  GROUP BY first_name
6.  HAVING cnt > 100
7.  ORDER BY cnt;
```

# Агрегатные функции MySQL

**AVG**: вычисляет среднее значение

**SUM**: вычисляет сумму значений

**MIN**: вычисляет наименьшее значение

**MAX**: вычисляет наибольшее значение

**COUNT**: вычисляет количество строк в запросе

# JOIN

```
SELECT h.name, a.name
FROM heroes h, abilities a
WHERE h.id = a.hero_id;

SELECT h.name, a.name
FROM heroes h
INNER JOIN abilities a ON h.id = a.hero_id;

SELECT h.name, a.name
FROM heroes h
LEFT JOIN abilities a ON h.id = a.hero_id;
```

# Вложенные запросы

```
SELECT title
FROM article t1
JOIN (
    SELECT rubric_id, MAX(id) max_id
    FROM article
    GROUP BY rubric_id LIMIT 5
) t2
ON t1.id = t2.max_id;
```

# Операции SQL: INSERT, UPDATE, DELETE

```
1.  INSERT INTO users (name, age) VALUES ('Petr', 10);

2.  UPDATE users SET rating = rating + 1;
3.  UPDATE users SET age = 20 WHERE name = 'Petr';

4.  DELETE FROM users WHERE name = 'Masha';
5.  DELETE FROM users WHERE age > 150;
```

# Терминология

- **Индекс** — объект базы данных, создаваемый с целью повышения производительности поиска данных. Таблицы в базе данных могут иметь большое количество строк, которые хранятся в произвольном порядке, и их поиск по заданному критерию путём последовательного просмотра таблицы строка за строкой может занимать много времени. Индекс формируется из значений одного или нескольких столбцов таблицы и указателей на соответствующие строки таблицы и, таким образом, позволяет искать строки, удовлетворяющие критерию поиска. Ускорение работы с использованием индексов достигается в первую очередь за счёт того, что индекс имеет структуру, оптимизированную под поиск — например, сбалансированного дерева.

- **Кластерный индекс** – индекс, хранящий не только значение колонки, но и данные всей строки. Может быть только 1 для таблицы.

# По каким полям надо делать индексы

- Индексы для полей, по которым происходит JOIN
- Индексы для полей, по которым фильтруются записи
- Индексы для полей, по которым идет сортировка

# Задачи проектирования

- Обеспечение хранения всей необходимой информации
- Обеспечение возможности получения данных по всем запросам
- Сокращение избыточности и дублирования данных
- Обеспечение целостности данных

# Типы данных в MySQL

INT - Целое число нормального размера. Диапазон со знаком от -2147483648 до 2147483647. Диапазон без знака от 0 до 4294967295.

DOUBLE - Число с плавающей точкой удвоенной точности нормального размера. Допустимые значения:
от -1,7976931348623157E+308 до -2,2250738585072014E-308, 0, и
от 2,2250738585072014E-308 до 1,7976931348623157E+308. Если указан атрибут UNSIGNED, отрицательные значения недопустимы.

DATE - Дата. Поддерживается интервал от '1000-01-01' до '9999-12-31'. MySQL выводит значения DATE в формате 'YYYY-MM-DD', но можно установить значения в столбец DATE, используя как строки, так и числа. See section 6.2.2.2 Типы данных DATETIME, DATE и TIMESTAMP.

DATETIME - Комбинация даты и времени. Поддерживается интервал от '1000-01-01 00:00:00' до '9999-12-31 23:59:59'.

TIMESTAMP - Временная метка.

TIMEB - Время. Интервал от '-838:59:59' до '838:59:59’.

YEAR - Год в двухзначном или четырехзначном форматах (по умолчанию формат четырехзначный).

# Больше типов данных

CHAR(M) [BINARY] - Строка фиксированной длины, при хранении всегда дополняется пробелами в конце строки до заданного размера. Диапазон аргумента M составляет от 0 до 255 символов. Если не задан атрибут чувствительности к регистру BINARY, то величины CHAR сортируются и сравниваются как независимые от регистра в соответствии с установленным по умолчанию алфавитом.

CHAR - Это синоним для CHAR(1).

VARCHAR(M) [BINARY] - Строка переменной длины.

TINYBLOB, TINYTEXT - Столбец типа BLOB или TEXT с максимальной длиной

255 (2^8 - 1) символов.

BLOB, TEXT - Столбец типа BLOB или TEXT с максимальной длиной 65535 (2^16 - 1) символов.

Больше типов и более подробная дока:

http://www.mysql.ru/docs/man/Column_types.html

# Проектируем БД

Спроектировать базу данных для магазина

# Анализ запросов: EXPLAIN

- Ничего не говорит о том как влияют на запросы триггеры.
- Не работает с хранимыми процедурами ( хотя можно разложить процедуру на запросы и выполнить каждый из них)
- Ничего не говорит об оптимизациях на этапе выполнения запроса
- Часть отображаемой информации оценочная.

# Explain: id

EXPLAIN select * from users_car where id LIKE "1%"

| id | select_type | table | partitions | type | possible_keys |
|---|---|---|---|---|---|
| 1 | SIMPLE | users_car | NULL | ALL | PRIMARY |

EXPLAIN select *, (SELECT 1 from users_user) from users_car where id LIKE "1%";

| id | select_type | table | partitions | type | possible_keys |
|---|---|---|---|---|---|
| 1 | PRIMARY | users_car | NULL | ALL | PRIMARY |
| 2 | SUBQUERY | users_user | NULL | index | NULL |

EXPLAIN SELECT 1 UNION ALL SELECT 1;

| id | select_type | table | partitions | type |
|---|---|---|---|---|
| 1 | PRIMARY | NULL | NULL | NULL |
| 2 | UNION | NULL | NULL | NULL |

# Explain: select_type

| id | select_type | table | partitions | type | possible_keys |
|---|---|---|---|---|---|
| 1 | PRIMARY | users_car | NULL | ALL | PRIMARY |
| 2 | SUBQUERY | users_user | NULL | index | NULL |

SIMPLE – Простой запрос SELECT без подзапросов или UNION

PRIMARY - Самый внешний запрос

SUBQUERY - Запрос Select, который содержится в подзапросе (не в From)

DERIVED - Значение DERIVED означает, что запрос SELECT является подзапросом в фразе FROM

UNION - Второй и последуюие запросы SELECT входящие в объединение union помечаются признаком UNION

UNION RESULT - Запрос SELECT, применяемый для выборки данных из временной таблицы созданной в ходе выполнения UNION

# Explain: table

EXPLAIN select * from users_car where id LIKE "1%"

| id | select_type | table | partitions | type | possible_keys |
|---|---|---|---|---|---|
| 1 | SIMPLE | users_car | NULL | ALL | PRIMARY |

EXPLAIN select * from users_car as uc join users_user as uu on uc.user_id=uu.id;

| id | select_type | table | partitions | type |
|---|---|---|---|---|
| 1 | SIMPLE | uc | NULL | ALL |
| 1 | SIMPLE | uu | NULL | eq_ref |

# Explain: type

| id | select_type | table | partitions | type |
|---|---|---|---|---|
| 1 | SIMPLE | uc | NULL | ALL |
| 1 | SIMPLE | uu | NULL | eq_ref |

ALL - Этот подход обычно называют сканированием таблицы.

index - То же, что и сканирование таблицы, но MySQL просматривает записи в порядке задаваемом индексом, а не в порядке следования строк.

range - Просмотр диапазона – неполное сканирование индекса.

ref - доступ по индексу, возвращает строки соответствующие единственному заданному значению

eq_ref - поиск по индексу в случае если MySQL точно знает, что будет возвращено 1 значение.

Null - запрос на фазе оптимизации разрешен так, что не потребовалось обращаться к таблицам базы данных

# Explain: possible_keys, key

EXPLAIN select id from users_user\G;

```
*************************** 1. row ***************************
           id: 1
  select_type: SIMPLE
        table: users_user
   partitions: NULL
         type: index
possible_keys: NULL
          key: users_user_c9e9a848
      key_len: 4
          ref: NULL
         rows: 12024
     filtered: 100.00
        Extra: Using index
1 row in set, 1 warning (0,01 sec)
```

# NoSQL Rising

# Общие характеристики NoSQL БД

- Не используют реляционную модель
- Хорошо подходят для развертывания на кластере
- Open-source
- Schemaless

# NoSQL: key-value СУБД

**Кейсы применения БД хранилищ ключ-значение:**

- Кеширование - быстрое и частое сохранение данных для будущего использования
- Очередь - некоторые БД типа ключ-значение поддерживают списки, наборы и очереди
- Распределение информации/задач - используется для реализации паттерна Pub/Sub
- Живое обновление информации - приложения использующие состояния

**Популярные решения:**

Memcached / MemcacheDB - распределённая БД в оперативной памяти

Redis - БД в оперативной памяти с поддержкой структур данных и возможностью выполнять операции на данных

…

# NoSQL: распределенные СУБД

**Кейсы применения распределенных СУБД:**

Хранение неструктурированных, не разрушаемых данных - если вам необходимо хранить большие объемы данных в течение долгого времени, то такие БД очень хорошо справятся с задачей

Масштабирование - по задумке такие базы данных легко масштабируются.

**Популярные СУБД:**

Cassandra - структура данных основана на BigTable и DynamoDB

HBase - хранилище для Apache Hadoop основанное на принципах BigTable

# NoSQL: документоориентированные СУБД

**Кейсы применения документоориентированные СУБД:**

**Популярные СУБД**

MongoDB - очень популярное и функциональное хранилище

Couchbase - основанное на JSON, совместимое с Memcached хранилище

CouchDB - передовое документо-ориентированное хранилище

# NoSQL: СУБД типа граф

**Кейсы применения распределенных СУБД:**

работа со сложно связанной информацией. Например граф знакомств в соц сети.

Моделирование и поддержка классификаций - такие БД преуспели везде где есть связи. Моделирование данных и классификация различной информации по связям можно с легкостью представить используя эти БД.

**Популярные СУБД**

OrientDB - очень быстрое документо-ориентированное хранилище гибрид типа граф написанное на Java. Включает в себя разные режимы работы

Neo4J - безсхемное, очень мощное и популярное хранилище написанное на Java

# SQL подход к проектированию БД

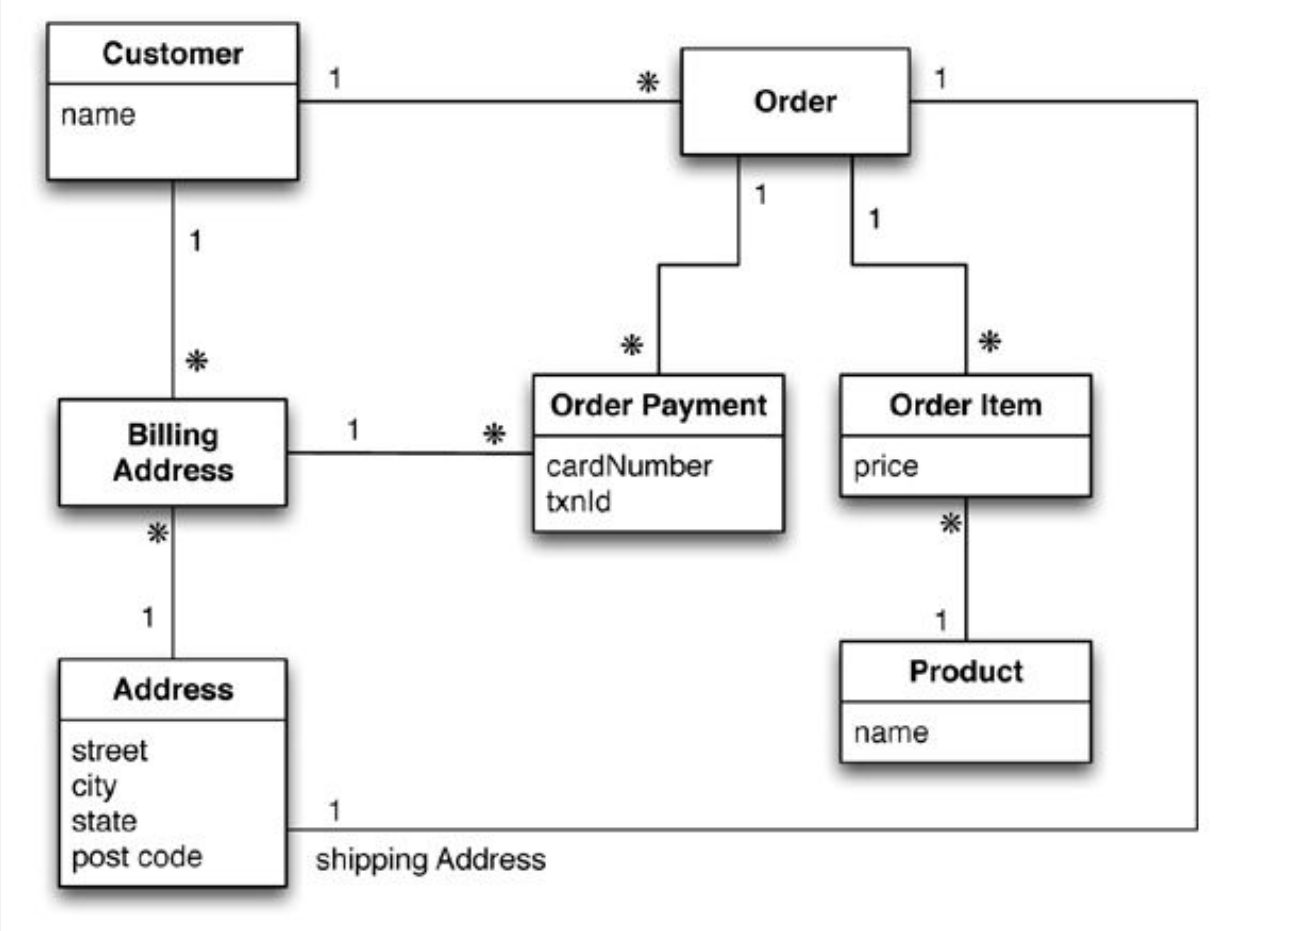

# NoSQL подход

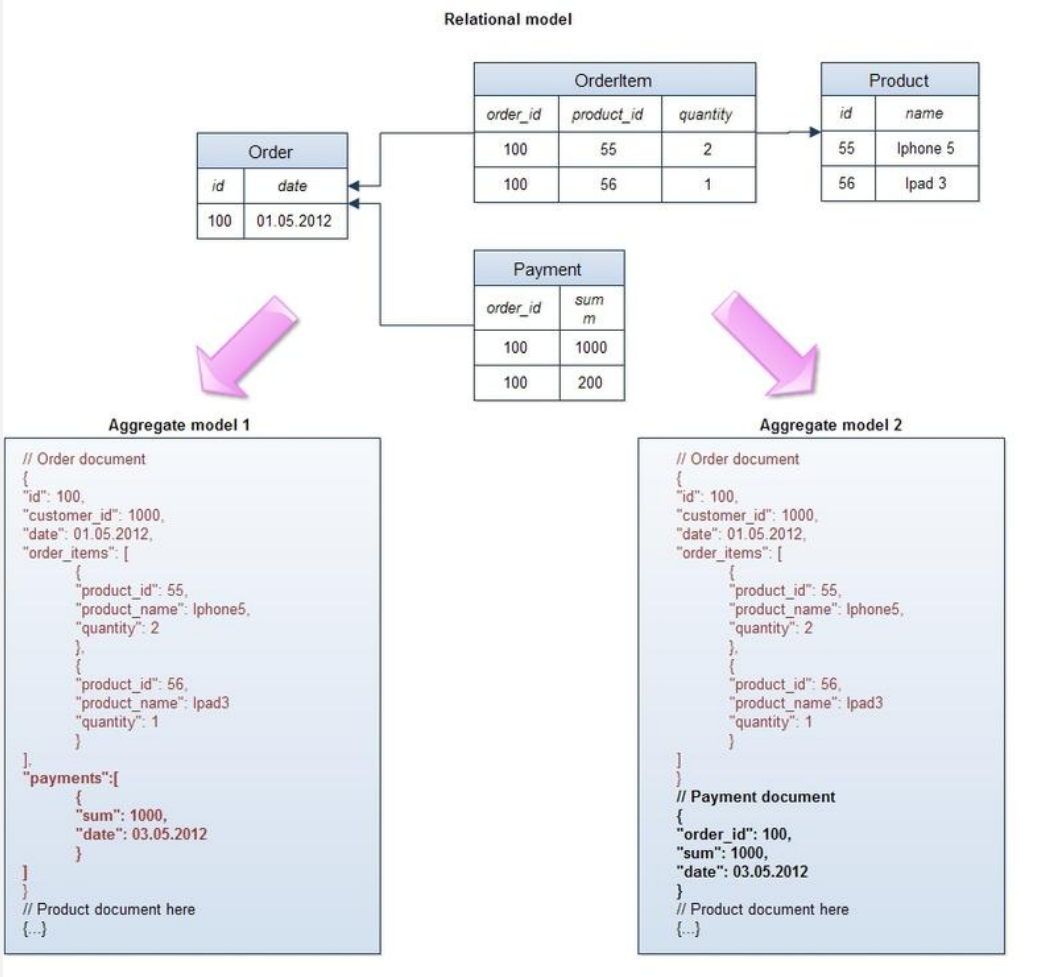

# Разница подходов

| Нормализация данных | Данные в виде агрегатов |
|---|---|
| • Целостность информации при обновлении (меняем запись в одной таблице, а не в нескольких)<br>• Ориентированность на широкий спектр запросов к данных | • Оптимизация только под определенный вид запросов<br>• Сложности при обновлении денормализованных данных |
| • Неэффективна в распределенной среде<br>• Низкая скорость чтения при использовании объединений (joins)<br>• Несоответствие объектной модели приложения физической структуре данных (impedance mismatch, решается с помощью Hibernate etc.) | • Лучший способ добиться большой скорости на чтение в распределенной среде<br>• Возможность хранить физически объекты в том виде, в каком с ними работает приложение (легче кодировать и меньше ошибок при преобразовании)<br>• Родная (native) поддержка атомарности на уровне записей |