СУБД и приложение

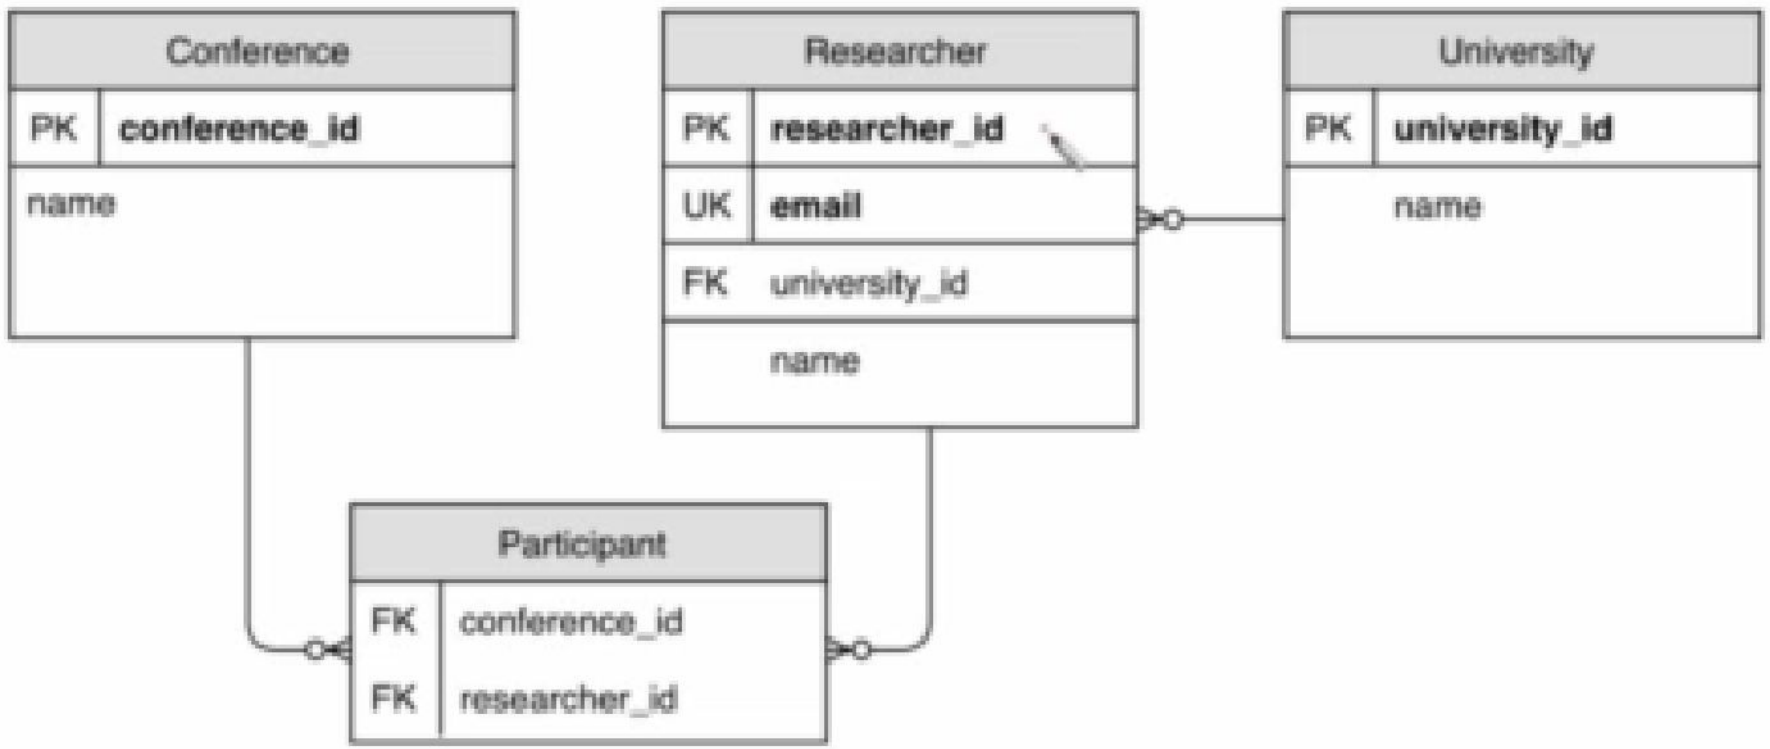
Conference
PK
conference_id
name
Researcher
PK
researcher_id
UK
email
FK
university_id
name
University
PK
university_id
name
Participant
FK
conference_id
FK
researcher_id

Для каждой пары

$$(конференция, университет)$$

найти суммарное количество исследователей из данного университета, участвовавших в данной конференции.

- 200 записей в University
- 1000 записей в Conference
- 20000 записей в Researcher
- 100000 записей в Participant

```
# db.execute выполняет запрос и возвращает результат
# в виде массива словарей
conferences = db.execute('SELECT * FROM Conference')
for conf in conferences:
  selectParts = '''
    SELECT * FROM Participant
    WHERE conference_id = ''' + conf['conference_id']
  for p in db.execute(selectParts):
    researcher = db.execute('''
      SELECT * FROM Researcher
      WHERE researcher_id=''' + p['researcher_id'])
    uni_id = researcher['university_id']
    uni = db.execute('''
      SELECT * FROM University
      WHERE university_id=''' + uni_id)
    # Инкрементируем счетчик
    inc(conf, uni)
```

- Сколько же времени будет выполняться продемонстрированный скрипт?

  1 секунду
  5 секунд
  20 секунд
  40 секунд
  1 минуту
  5 минут

Жизнь простого запроса

- Приложение посылает текст серверу БД
- Сервер делает синтаксический разбор запроса
- Проверяет использованные имена
- Составляет план выполнения запроса
- Выполняет запрос
- Формирует результат и отсылает приложению

- В таблице `Participant` 2-3 мегабайта и примерно 200-300 страниц
- 1000 просмотров выполнились бы за 1000 секунд
- Если бы страницы читались только с диска то один просмотр занял бы 1-2 секунды
- В самом хорошем случае за 10 секунд

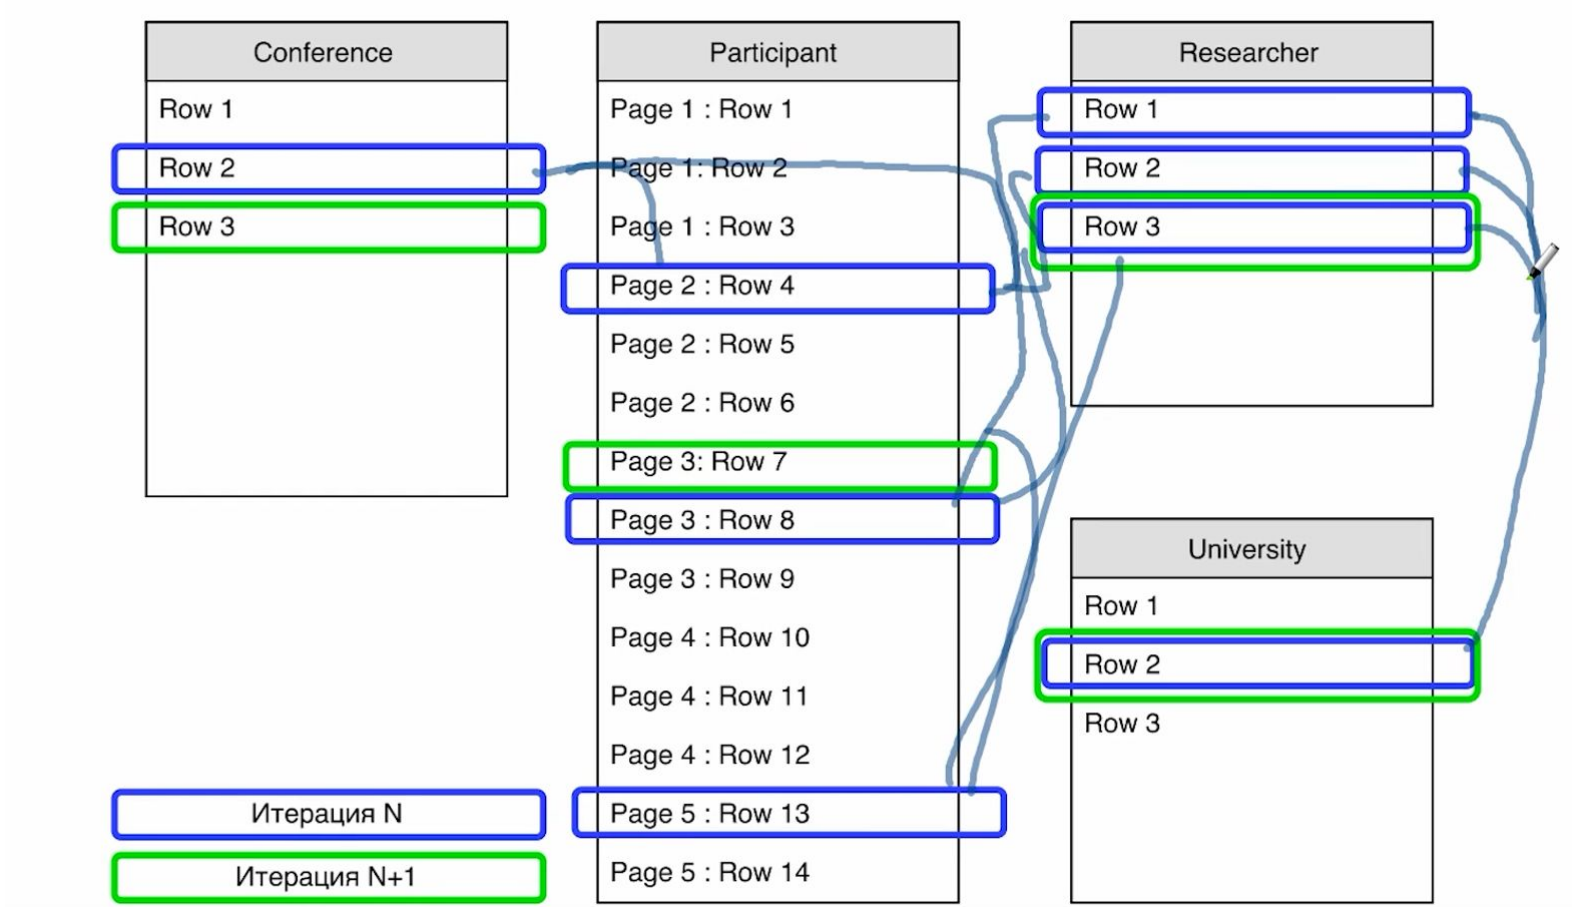
Conference
Row 1
Row 2
Row 3
Participant
Page 1 : Row 1
Page 1: Row 2
Page 1 : Row 3
Page 2 : Row 4
Page 2 : Row 5
Page 2 : Row 6
Page 3: Row 7
Page 3 : Row 8
Page 3 : Row 9
Page 4 : Row 10
Page 4 : Row 11
Page 4 : Row 12
Page 5 : Row 13
Page 5 : Row 14
Researcher
Row 1
Row 2
Row 3
University
Row 1
Row 2
Row 3
Итерация N
Итерация N+1

Сколько строк получится в результате выполнения этого запроса, если в таблице Foo 100 строк, в таблице Bar 50 строк и в таблице Baz 30 строк?

```
-- Таблицы выглядят так:
-- Baz(id INT PRIMARY KEY, <что-то еще>)
-- Bar(id INT PRIMARY KEY, baz_id INT NOT NULL REFERENCES Baz,  <что-то еще>)
-- Foo(id INT PRIMARY KEY, bar_id INT NOT NULL REFERENCES Bar,  <что-то еще>)
SELECT *
FROM Foo
JOIN Bar ON Foo.bar_id = Bar.id
JOIN Baz ON Bar.baz_id = Baz.id
```

30
50
100
5000
1500
3000
150000
180

Выполнение последовательности соединений:

1. Соединение Conference JOIN Participant

```
Conference          Participant
=============      ============================
id   name           conference_id researcher_id
-------------      ----------------------------
1    Conf1          2             100
2    Conf2          2             101
                    1             98

Conference JOIN Participant
============================================================
Conference.id  name  Participant.conference_id researcher_id
------------------------------------------------------------
1              Conf1 1                         98
2              Conf2 2                         100
2              Conf2 2                         101
```

2. Соединение (Conference JOIN Participant) JOIN Researcher

```
Conference JOIN Participant
============================================================
Conference.id  name  Participant.conference_id researcher_id
------------------------------------------------------------
1              Conf1 1                         98
2              Conf2 2                         100
2              Conf2 2                         101
```

```
Researcher
============================
id   name      university_id
----------------------------
98   Jennifer  239
101  Donald    566
100  Jeffrey   239


Conference C JOIN Participant P JOIN Researcher R
=================================================================================================
C.id  name  P.conference_id P.researcher_id R.id            R.name    R.university_id
-------------------------------------------------------------------------------------------------
1     Conf1 1              98              98              Jennifer  239
2     Conf2 2              100             100             Jeffrey   239
2     Conf2 2              101             101             Donald    566
```

3. Соединение ((Conference JOIN Participant) JOIN Researcher) JOIN University

```
Conference C JOIN Participant P JOIN Researcher R
=================================================================================
C.id  name  P.conference_id P.researcher_id R.id   R.name    R.university_id
---------------------------------------------------------------------------------
1     Conf1 1              98              98     Jennifer  239
2     Conf2 2              100             100    Jeffrey   239
2     Conf2 2              101             101    Donald    566


University
======================
university_id  name
----------------------
239            Stanford
566            ETH


-- в таблице ниже пропущены повторяющиеся столбцы researcher_id, university_id
--
Conference C JOIN Participant P JOIN Researcher R JOIN University U
=============================================================================================
C.id  name  conference_id R.id            R.name    university_id U.name
---------------------------------------------------------------------------------------------
1     Conf1 1             98              Jennifer  239           Stanford
2     Conf2 2             100             Jeffrey   239           Stanford
2     Conf2 2             101             Donald    566           ETH
```

```
EXPLAIN ANALYZE
    SELECT Conference.name, University.name
    FROM Conference JOIN Participant ON
      (Conference.conference_id = Participant.conference_id)
    JOIN Researcher ON
      (Participant.researcher_id = Researcher.researcher_id)
    JOIN University ON
      (Researcher.university_id = University.university_id)
```

```
Hash Join
  Hash Cond: (p.conference_id = c.conference_id)
  ->  Hash Join
        Hash Cond: (p.researcher_id = r.researcher_id)
        ->  Seq Scan on Participant p
        ->  Hash
              ->  Hash Join
                    Hash Cond: (
                        r.university_id = u.university_id
                    )
                    ->  Seq Scan on Researcher r
                    ->  Hash
                          ->  Seq Scan on University u
  ->  Hash
        ->  Seq Scan on Conference c
Planning time: 1.033 ms
Execution time: 93.119 ms
```

Hash Join

Выполняет соединение $R \bowtie S$ за $B(R + S)$ операций чтения диска, где $B(R + S)$ – суммарное количество дисковых страниц в обеих таблицах, при условии что одна из таблиц помещается в памяти

Псевдокод алгоритма HashJoin

```
# Выполняет соединение r и s по условию r.r_join_attr = s.s_join_attr
HashJoin(Relation r, Relation s, String r_join_attr, String s_join_attr):
  # проходим по всей таблице r и
  # строим словарь с дубликатами, где ключом является значение атрибута соединения из r
  # а в списке значений содержатся строки r
  hash_multimap = new HashMultimap()
  for r_page in r.pages():
    for r_row in r_page.rows():
      hash_multimap[r_row.value(r_join_attr)].add(r_row)

  # проходим по всей таблице s и для каждой строки проверяем наличие в построенном словаре
  # ключа равного значению атрибута соединения из s
  for s_page in s.pages():
    for s_row in s_page.rows():
      if s_row.value(s_join_attr) in hash_multimap:
        for r_row in hash_multimap.values(s_row.value(s_join_attr)):
          # Если таковой ключ найден то в результат отправляются все пары текущей строки из s
          # и списка значений из r
          emit(r_row, s_row)
```

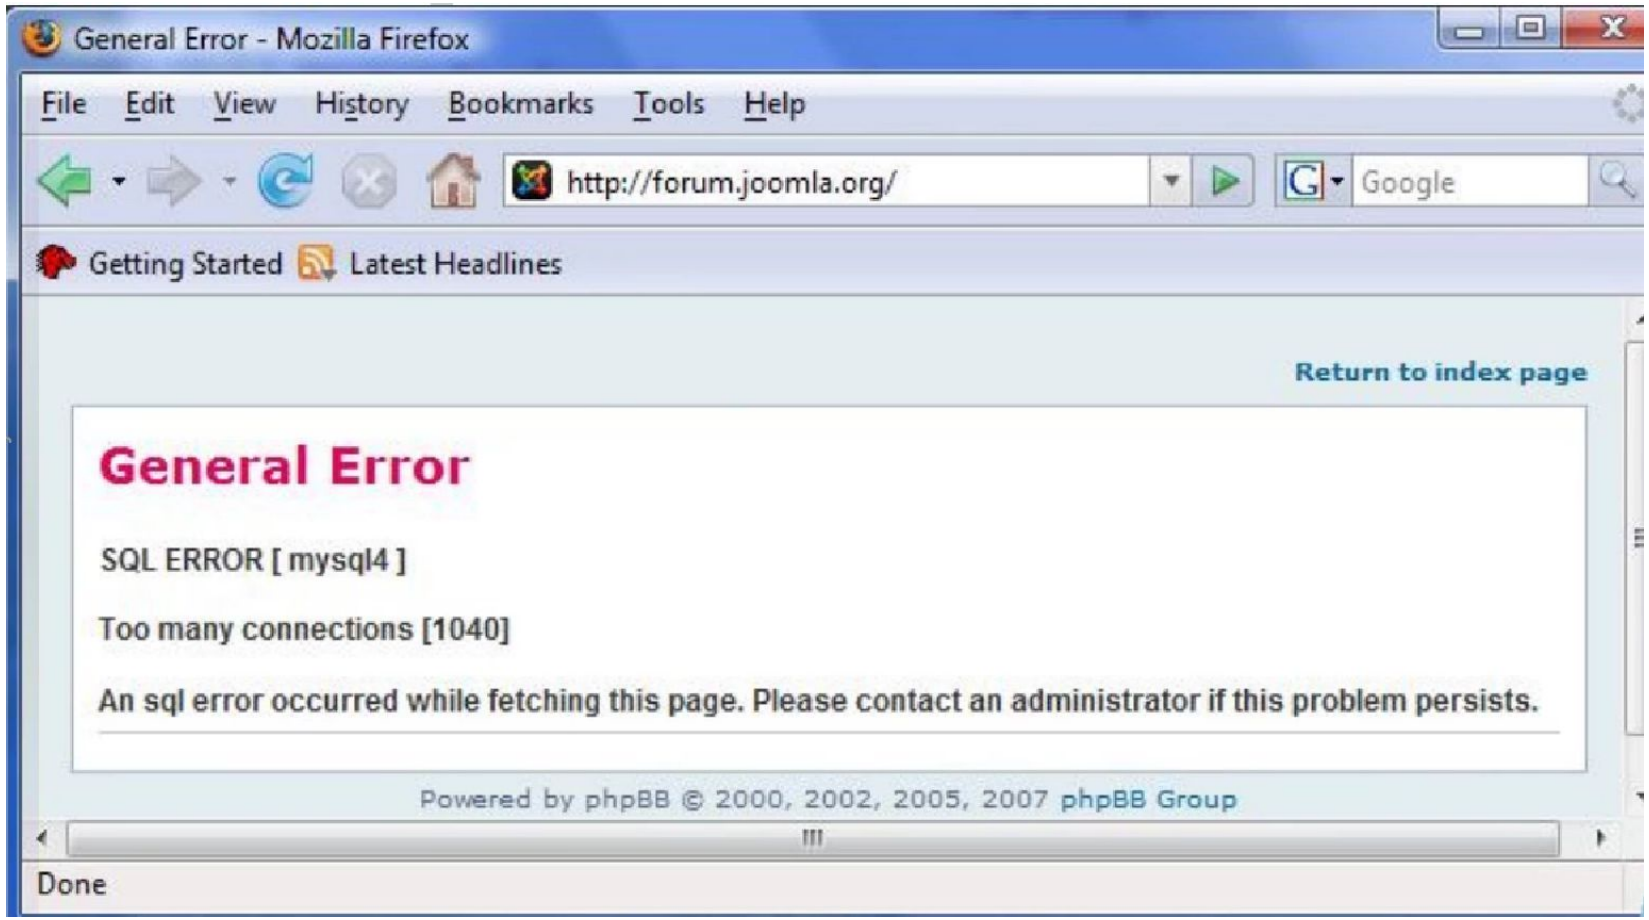
General Error - Mozilla Firefox
File Edit View History Bookmarks Tools Help
http://forum.joomla.org/
Google
Getting Started
Latest Headlines
Return to index page
General Error
SQL ERROR [mysql4]
Too many connections [1040]
An sql error occurred while fetching this page. Please contact an administrator if this problem persists.
Powered by phpBB © 2000, 2002, 2005, 2007 phpBB Group
Done

Соединение с СУБД

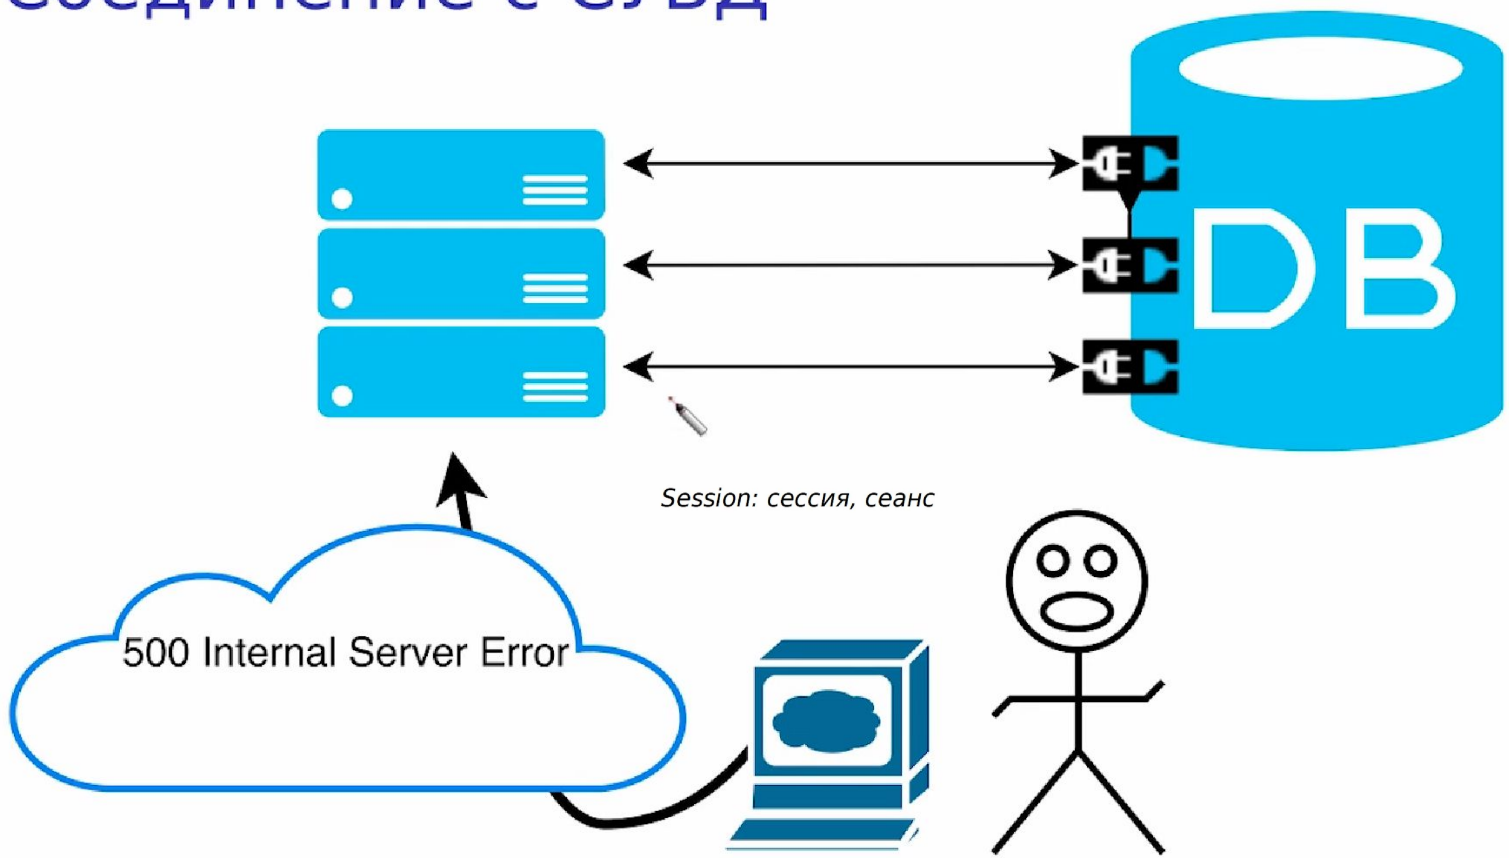

Session: сессия, сеанс

Connection: соединение, подключение, коннекция

Бывает подключение == сессия, бывает много сессий на одно подключение

Как устроенны сессии ?

- Сессии - это механизм, созданный для временного хранения и передачи информации между скриптами в пределах одного сайта.
- Сессии предусматривают возможность создания собственных способов обработки информации, поэтому, в принципе, можно использовать сессии и при работе с несколькими сайтами или даже с несколькими серверами.

Что произойдет с этим скриптом, если запустить его на PostgreSQL с настройками по умолчанию?

```
import psycopg2 as pg_driver

# Инкапсулирует обращения к БД
class Researcher:
    def __init__(self, id, university_id):
        self.db = pg_driver.connect(user="postgres", host="localhost")
        self.id = id
        self.university_id = university_id

    def getUniversity(self):
        cur = self.db.cursor()
        cur.execute('''
SELECT name FROM University WHERE university_id={0}
'''.format(self.university_id))
        return cur.fetchone()[0]

researchers = []
### Шаг 1: получаем из базы всех исследователей
cur = pg_driver.connect(user="db", password="q", host="localhost", dbname="db").cursor()
cur.execute("SELECT researcher_id, university_id FROM Researcher")

### Шаг 2: создаем объекты доступа к данным
for r in cur.fetchall():
    researchers.append(Researcher(r[0], r[1]))

### Шаг 3: печатаем университет, в котором работает каждый исследователь
for r in researchers:
    print r.getUniversity()
```

В PostgreSQL существуют все необходимые объекты (пользователь, БД, таблицы), параметры соединения правильные, в таблицах есть данные и они согласованы. Всё хорошо, в общем.

Скрипт выполнится без ошибок в любом случае

Если в таблице Researcher >= 100 записей то скрипт аварийно завершится, ничего не напечатав

Если в таблице Researcher >= 100 записей то скрипт напечатает сведения о первых 99, после чего закончит свою работу, возможно, аварийно

Скрипт выполнится без ошибок, если в таблице Researcher меньше 100 записей

```
# vim m3_connection_demo1.py
# python m3_connection_demo1.py
Traceback (most recent call last):
  File "m3_connection_demo1.py", line 26, in <module>
    researhers.append(Researcher(r[0], r[1]))
  File "m3_connection_demo1.py", line 8, in __init__
    self.db = pg_driver.connect(user="db", password="q", host="localhost", dbname="db")
  File "/usr/lib/python2.7/dist-packages/psycopg2/__init__.py", line 179, in connect
    connection_factory=connection_factory, async=async)
psycopg2.OperationalError: FATAL:  sorry, too many clients already
```

```
db=# SELECT COUNT(*) FROM Researcher;
 count
-------
    20
(1 row)

db=# ^D\q
# python m3_connection_demo1.py
Uni35
Uni111
Uni121
Uni83
Uni78
Uni96
Uni138
Uni11
Uni50
Uni4
Uni90
Uni73
Uni136
Uni52
Uni101
Uni68
Uni105
Uni87
Uni152
Uni190
#
```

Сессии: как быть?

- Закрывать сессии

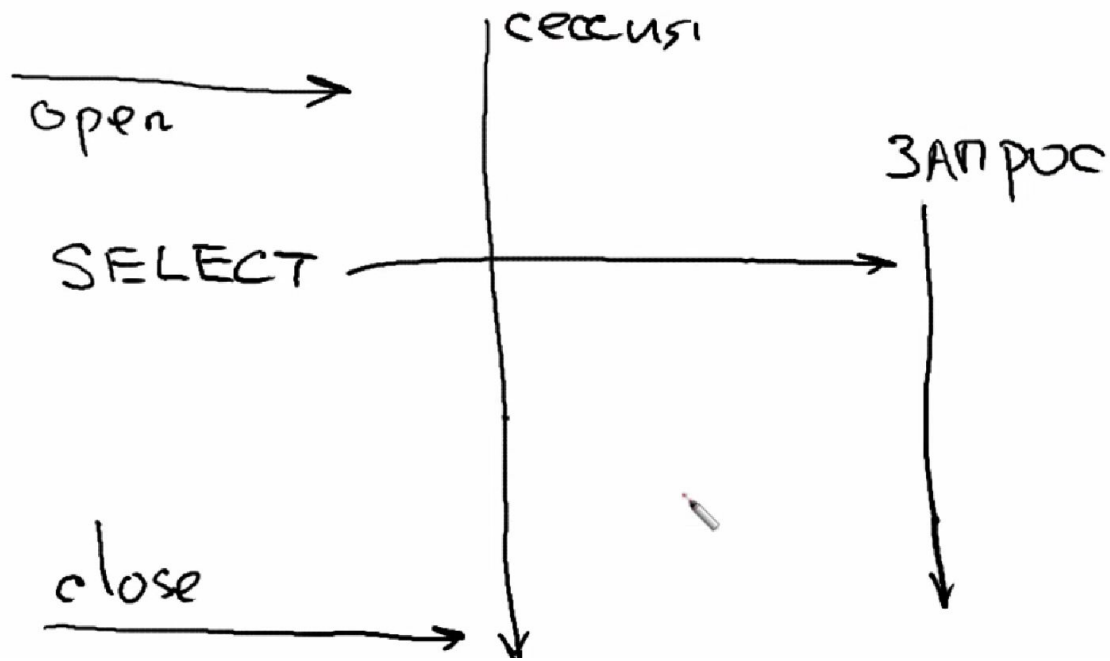

Закрывать сессии

Python	`try-finally`, `with`
Java	`try-finally`, try with resources
C++	деструкторы, умные указатели

```
# time python m3_connection_demo2.py
```

```
 Uni60
 Uni80
 Uni18

 real    0m1.260s
 user    0m0.080s
 sys     0m0.032s
```

```
Uni156
Uni60
Uni80
Uni18

real    0m0.081s
user    0m0.024s
sys     0m0.008s
```

- Пулы сеансов позволяют приложениям повторно использовать подключения к репозиторию внутри приложения или между различными приложениями. Пулы сеансов также можно использовать для ограничения количества подключений к репозиторию, выполняемых приложением во время пиковой активности. Пулы сеансов также сводят к минимуму количество входов и выходов из репозитория, необходимых для выполнения действий с репозиторием, и предотвращают накладные расходы, вызванные подключениями для входа в репозиторий.

Пул сеансов — это механизм распределенного объединения, что означает, что пул сеансов может отслеживать ресурсы для нескольких приложений, работающих на любом количестве серверов. На рисунке 1 показана одна из возможных конфигураций.

Рисунок 1. Архитектура пула сеансов

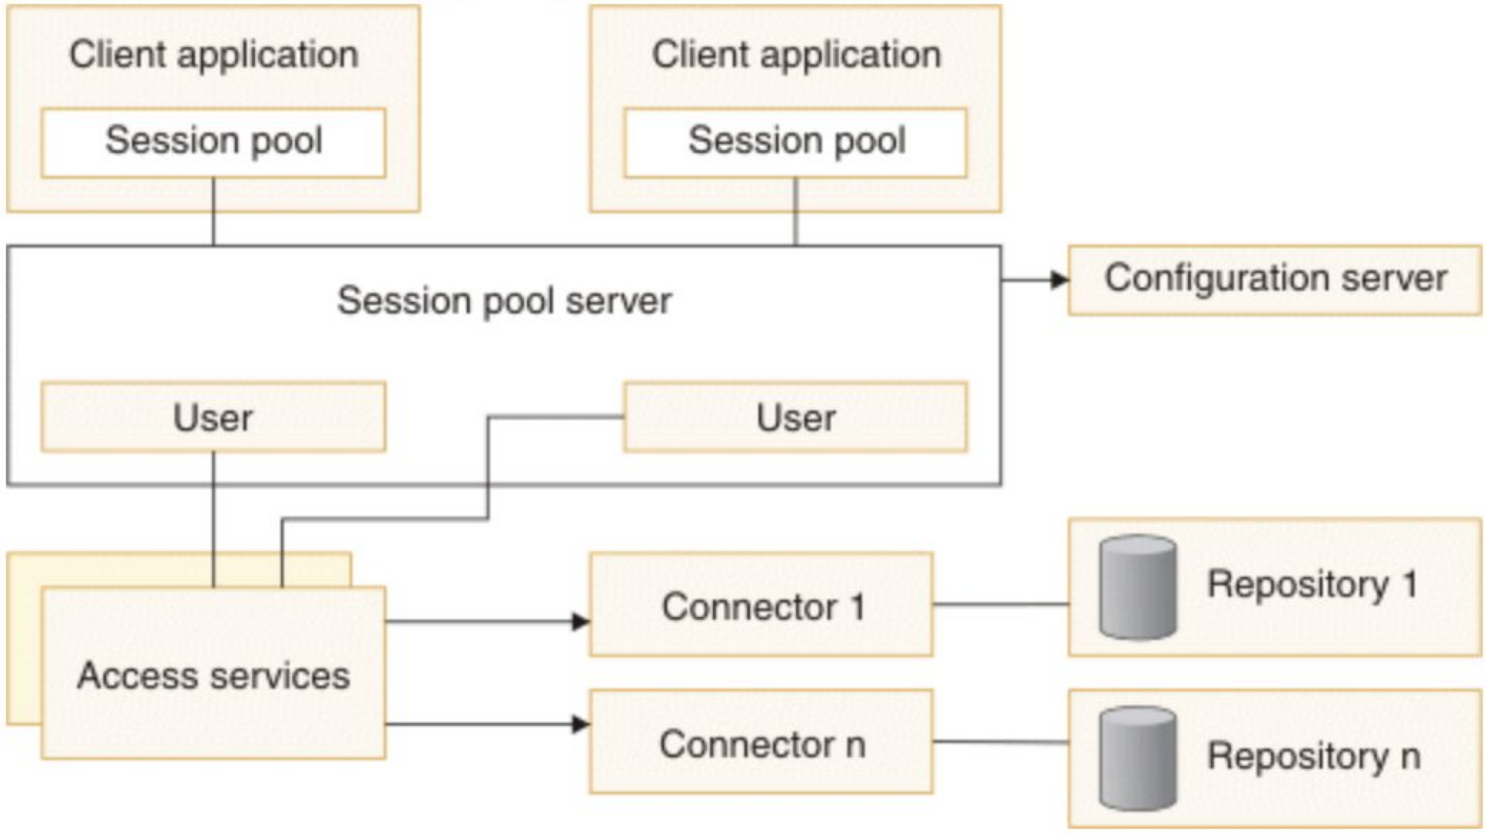

```python
import psycopg2 as pg_driver
import psycopg2.pool as pool

pg_pool = pool.SimpleConnectionPool(1, 2, user="db", password="q", host="localhost", dbname="db")
# Инкапсулирует обращения к БД
class Researcher:
    def __init__(self, id, university_id):
        self.id = id
        self.university_id = university_id

    def getUniversity(self):
        db = pg_pool.getconn()
        try:
            cur = db.cursor()
            cur.execute('''
                SELECT name FROM University WHERE university_id={0}
                '''.format(self.university_id))
            return cur.fetchone()[0]
        finally:
            pg_pool.putconn(db)

researchers = []
### Шаг 1: получаем из базы всех исследователей
cur = pg_driver.connect(user="db", password="q", host="localhost", dbname="db").cursor()
cur.execute("SELECT researcher_id, university_id FROM Researcher")

### Шаг 2: создаем объекты доступа к данным
for r in cur.fetchall():
    researchers.append(Researcher(r[0], r[1]))

### Шаг 3: печатаем университет, в котором работает каждый исследователь
for r in researchers:
    print r.getUniversity()
```

```
Uni25
Uni63
Uni157

real    0m0.134s
user    0m0.032s
sys     0m0.016s
```

"m3_connection_demo4.py" 35L, 1294C

Не перекладывай работу СУБД на приложение

Закрывай сессии

Пользуйся пулом сессий

Параметризуй контекстом объекты доступа к данным

- Представьте себе, что вы программист, занимающийся производительностью вашего приложения. Вы увидели приведённый ниже код на языке Python и поняли, что он занимает слишком много времени. Попробуйте переписать его одним запросом.
- Решением является текст SQL запроса. Обратите внимание на очередность столбцов в ответе. Прочими различиями в формате текстового вывода питона и SQL пренебрегите.

- Схема БД

- CREATE TABLE Spacecraft(
- id SERIAL PRIMARY KEY,
- name TEXT UNIQUE,
- service_life INT DEFAULT 1000,
- birth_year INT CHECK(birth_year > 0)
-);

- CREATE TABLE Planet(
- id SERIAL PRIMARY KEY,
- name TEXT UNIQUE,
- distance NUMERIC(5,2)
-););

```
CREATE TABLE Commander(
  id SERIAL PRIMARY KEY,
  name TEXT
);

CREATE TABLE Flight(
  id INT PRIMARY KEY,
  spacecraft_id INT REFERENCES Spacecraft,
  planet_id INT REFERENCES Planet,
  commander_id INT REFERENCES Commander,
  start_date DATE,
  UNIQUE(spacecraft_id, start_date),
  UNIQUE(commander_id, start_date)
```

Код на Python

```
# encoding: utf-8
import psycopg2 as pg_driver

# Postgres, запущенный в докере, не требует пароля, если клиент находится на localhost
db = pg_driver.connect(user="postgres", host="localhost")
cur = db.cursor()

def fun1(commander_id):
  result = []
  cur.execute("SELECT commander_id, spacecraft_id, start_date FROM Flight")
  for flight in cur.fetchall():
    if flight[0] != commander_id:
      continue
    cur.execute("SELECT id, name FROM Spacecraft")
    for spacecraft in cur.fetchall():
      if spacecraft[0] == flight[1]:
        result.append((spacecraft, flight)) # добавляем в результат пару
  return result
```

```
def fun2(commander_id):
  result = []
  for spacecraft, flight in fun1(commander_id):
    cur.execute("SELECT id, name FROM Commander")
    for cmndr in cur.fetchall():
      if cmndr[0] == flight[0]:
        result.append((cmndr[1], spacecraft[1], flight[2])) # добавляем в результат тройку
  return result

for row in fun2(6):
  print row
```