

# PostgreSQL 前世今生

digoal

阿里云

2016Postgres中国用户大会

# 议题

- PostgreSQL 前世今生
- PostgreSQL 社区理念
- 阿里云PostgreSQL内核优化

2016Postgres中国用户大会


# PostgreSQL发展历史

混沌初开

全剧终?

见龙在田


金蝉脱壳



Michael Stonebraker



# 版本迭代



<https://en.wikipedia.org/wiki/PostgreSQL>

# 里程碑

7.2

2002年

- GIS
- PL/Python

穿越回到2002

2016Postgres中国用户大会

# PostGIS(覆盖民用、军用、科研)

- 类型

- 点

- 二维、三维（经纬度、海拔）、多维、地址类型

- 线

- 闭合线段、开放线段、多点线段

- 面

- 圆、椭圆、矩形、长方形、正方形、规则多边形、不规则多边形、曲面

- raster

- GIS图数据, jpegs, tiffs, pngs, digital elevation models
    - 测绘、航天、天文应用

- 拓扑

- 操作符


- 点面判断、距离、面积、体积、叠加、相减、长度、弧度、夹角、pixel相关运算、raster相关运算

- 索引

- 距离运算、距离排序、包含判断、相交判断、

- 函数

- 区域内线段长度（城市道路长度）、路径成本(坡度、长度、权重)计算、最佳路径计算、区域面积（城市面积）



# 里程碑

8.4

- SQL:2008
- 窗口查询
- 并行恢复
- 递归查询

2016Postgres中国用户大会

# 窗口查询 - 数据透视

- 数据结构

- 学号、**省份、城市、学校、年级、班级、科目**、分数




- 查询需求

- 学号、(**窗口**)、分数、并列名次、名次、与第一名的分差、与前一名的分差、第一名到当前学生的平均分（帧）、处于哪个分数区间（比如分了**10**个区间）

- 语法


- **window\_func()** over(partition by **part\_col?** order by **col?**)
    - first\_value()、lead(n)、lag(n)、dense\_rank()、ntile(bucket)、avg(), .....

# 递归查询 - 支持树形结构数据



# 递归查询 - 优化count(distinct)


2级索引，包括1个root page，  
1或多个branch page，多个  
leaf page。  
最多存储 $285^3$ 条记录。  
branch page是"双向链表"。



按层级收敛  
减少数据块扫描

# 并行恢复

- 逻辑备份集恢复
- 多表并行还原
- 多个索引并行创建



# 里程碑

9.0

- 异步流式复制
- 快速大版本升级
- online code


2016Postgres中国用户大会

# 异步流复制

- 基于REDO record, 异步流式复制(不需要等到xlog切换)
- **延迟毫秒**内
- 支持一主多备
- 备库read only时, 不影响接收redo
- 备库read only时, 不影响恢复 (除非恢复时要擦除已对记录持锁的查询)
- 主备物理**块级别一致**

# 快速大版本升级

- 元数据（1万张表 - 约十几MB）
  - 不管数据库多大，通常业务中断**分钟级别**
  - 元数据导出导入
  - 不需要动用户的数据文件
  - 统计信息需要重新收集



# 里程碑


## 9.1

- 同步流式复制
- KNN索引支持
- FDW接口

2016Postgres中国用户大会


# 同步流复制

- 用户可以根据事务可靠性要求，选择本事务是否需要同步复制。




# KNN查询索引支持

- 近邻查询
  - 根据经纬度查询最近用户
  - 根据数值查询最相邻数值
  - 根据文本相似度查询最相似文本
- 距离排序



# FDW接口



# 里程碑


9.2

- SP-GiST索引
- 范围类型
- JSON
- 支持plv8
- 级联流式复制

2016Postgres中国用户大会

# GiST取代B-Tree用于范围匹配查询

- 快速范围查询，**智能DNS**，判断来源IP落在哪个IP地址段内
- 传统方法
  - postgres=# create table tbl(id int,ip\_start int8,ip\_end int8);
  - postgres=# create index idx\_tbl on tbl using **btree(ip\_start,ip\_end)**;
- 使用范围类型
  - postgres=# create table tbl\_r(id int,ip\_range int8range);
  - postgres=# create index idx\_tbl\_r on tbl\_r using **spgist(ip\_range)**;
  - 或
  - postgres=# create index idx\_tbl\_r1 on tbl\_r using **gist(ip\_range)**;
- 传统范围查询
  - postgres=# select \* from tbl where ? **between ip\_start and ip\_end**;
- 使用范围类型的范围匹配操作符，利用gist/spgist索引
  - postgres=# select \* from tbl\_r where **ip\_range @> ?**
  - OR 不改变原有数据结构，使用 函数索引
  - create index idx on tbl using gist (int8range(ip\_start,ip\_end+1));
  - select \* from tbl where int8range(ip\_start,ip\_end+1) @> ?;




# JSON支持

- 非结构化数据JSON支持
- PLV8引擎，服务端编程
- JUST IO
- no op,am,func support

2016PostgreSQL中国用户大会

# 级联复制




# 里程碑

9.3


- 物化视图
- 简单视图
- 支持DML
- 可写FDW接口
- 事件触发器

2016PostgreSQL用户大会

# 物化视图



# 可写FDW



# 事件触发器

- 保护DBA，防止DBA误操作



当drop或truncate table时  
触发function1

function1中，根据触发事件的用户，删除或truncate重要的数据时  
抛出异常

保护DBA，防止DBA误操作

# 里程碑

2016Postgres中国用户大会

## 9.4

- JSONB
- 增量物化视图
- 逻辑流式复制
- 缓存预热
- 正则查询支持索引

# JSONB

- 全面支持
  - IO、OP、AM、func
- 任意KEY或VALUE的索引支持
- VALUE支持numeric, string, time, array, 嵌套json等
- 支持常用的JSON类型查询，构造符


# 多Master复制

- 基于redo的逻辑复制
- 数据冲突handler
- 自定义冲突handler

2016Postgres中国用户大会

# 防止雪崩

- 缓存预热
- set query timeout



# 高效(秒、毫秒级)模糊检索、分词

- 英语分词性能: ~ 900万 words每秒 ( Intel(R) Xeon(R) CPU X7460 @ 2.66GHz )
- 中文分词性能: ~ 400万 字每秒 ( Intel(R) Xeon(R) CPU X7460 @ 2.66GHz )
- 英文分词+插入性能: ~ 666万 字每秒 ( Intel(R) Xeon(R) CPU X7460 @ 2.66GHz )
- 中文分词+插入性能: ~ 290万 字每秒 ( Intel(R) Xeon(R) CPU X7460 @ 2.66GHz )

- 高效(秒、毫秒级) 模糊查询、正则匹配 (支持中文, 支持GIN索引查询)
- 传统方式 全表扫描, **百亿**数据的查询响应至少是**小时级**别。
- PostgreSQL使用GIN R-TREE索引可以将查询时间缩短到**秒级**。
  - 公安刑侦、车牌、地址、邮箱。。。查询、

```
select 'postregsql' % 'postgresql';
      postgres=# select similarity('postregsql','postgresql');
      similarity
-----
          0.375
(1 row)
```

```
select * from tbl where info ~ '^????6888$';
select * from tbl where info ~ '^????688?.$';
```

前后遮挡的才是高手  
但是也逃不过  
PostgreSQL的法眼



性能与ElasticSearch  
差不多

# 里程碑

2016Postgres中国用户大会

9.5

- BRIN索引接口
- 多核性能增强
- OLAP增强
- 多维分析
- customSCAN接口
- 采样接口
- GPU并行加速器

# 流式数据 - 块级索引 BRIN

- 支持适合流式数据的索引
  - 某电子商务网站的用户浏览行为记录
  - 每分钟70万条记录(一天约10亿记录)
  - 每10分钟统计一次最近的行为并合并结果(范围扫描), 15个统计维度

物理存储顺序 & 值的顺序

线性相关性好



# BRIN索引 和 B-tree索引的对比

- btree (全记录索引)

- value1,ctid
- value2,ctid
- .....
- **big**
- full

B-tree  
大而全




BRIN  
小而美



- brin (块粒度索引)

- blockid\_left, blockid\_right, value\_min, value\_max, allnull?, hasnull?
- .....
- **small**
- lossy

流式数据  
范围  
增量计算



# GIS数据结合窗口、多维分析

解决了哪几个问题


1. 避免冗余扫描和计算
1. 每个大范围的数据只需要扫一次
2. 解决灵活多变的多维透视需求

多个字段任意组合，指定组合的聚合  
查询结果快速查询



Grouping Sets

Cube

Rollup



# Custom Scan - GPU并行计算



# 里程碑


2016Postgres中国用户大会

9.6


- 多核并行计算
- 多副本同步流式复制
- snapshot too old
- FDW join,sort,update,delete下推
- 多核增强 (500W+) QPS

# 并行计算 - 精准营销

- 用户画像数据（标签 - BITS）
- 数据量**10亿级**
  - 用户提交查询条件(BITs)
  - bit and (包含什么bit)
  - bit xor (不包含什么bit)
- 性能提升与CPU成线性(case by case)
- 已支持
  - Seqscan、JOIN、agg



# 金融级 - 多副本可靠性



# 前端 - 任意维度勾选

- 任意维度组合
- bloom index
- <https://yq.aliyun.com/articles/51131>




The image shows a search interface for PostgreSQL instances. At the top, there is a search bar with a dropdown menu for '实例名' (Instance Name) and a '高级搜索' (Advanced Search) button. Below the search bar, there are several rows of filter options, each with a label and a dropdown menu or input field. The filters include:

- 实例名: [Input Field]
- 用户连接: [Input Field]
- 用户信息: [Input Field]
- 可用区: [请选择] 集群名: [请选择]
- 库类型: [请选择] 库版本: [请选择]
- 实例类型: [请选择] 网络类型: [请选择]
- VIP类型: [请选择] TOP类型: [请选择]
- 实例状态: [请选择] 锁定模式: [请选择]
- 服务状态: [请选择] 是否非标: [请选择]
- SQL WALL: [请选择] 业务类型: [请选择]
- 实例角色: [请选择] 网络MODE: [请选择]
- 过期时间: [Input Field] 至 [Input Field]
- 创建时间: [Input Field] 至 [Input Field]

At the bottom of the form, there is a '搜索' (Search) button.


# others



smooth fsync

聚合(init-cond, sfunc)代码共用  
性能与op数量程线性提升

## scale-up



wait event

snapshot too old

sharding based on FDW

join, sort, where push down

sort 性能增强

# 里程碑


2016Postgres中国用户大会

其他插件

# GIS业务 - 最佳路径计算

## Routing Functions

- **All pairs** - All pair of vertices.
  - **pgr\_floydWarshall** - Floyd-Warshall's Algorithm
  - **pgr\_johnson** - Johnson's Algorithm
- **pgr\_astar** - Shortest Path A\*
- **pgr\_bdAstar** - Bi-directional A\* Shortest Path
- **pgr\_bdDijkstra** - Bi-directional Dijkstra Shortest Path
- **dijkstra** - Dijkstra family functions
  - **pgr\_dijkstra** - Dijkstra's shortest path algorithm.
  - **pgr\_dijkstraCost** - Use pgr\_dijkstra to calculate the costs of the shortest paths.
- **Driving Distance** - Driving Distance
  - **pgr\_drivingDistance** - Driving Distance
  - Post processing
    - **pgr\_alphaShape** - Alpha shape computation
    - **pgr\_pointsAsPolygon** - Polygon around set of points
- **pgr\_ksp** - K-Shortest Path
- **pgr\_trsp** - Turn Restriction Shortest Path (TRSP)
- **pgr\_tsp** - Traveling Sales Person



支持线段双向权重设定

上坡: + weight  
下坡: - weight



# 图像搜索

Wavelet算法  
下沉至PG内核

Input image ( $2^N \times 2^N$ )



wavelet transform

Transformed image ( $2^N \times 2^N$ )



相似图片 | 相似人脸

更多 >>



## The Haar 2-D Wavelet Transform

The 2-D Haar Wavelet Transform corresponds to a modification of this minimal recursive transform

Input image ( $2^N \times 2^N$ )



Step 1

Wavelet image representation ( $2^N \times 2^N$ )

Average Image: every pixel A is the average of pixels 1,2,3,4	Detail image
Detail image	Detail image

# 基因测序

- DNA库，如何配对，下一代最优




## New data types:

- DNA\_SEQUENCE
- RNA\_SEQUENCE
- AA\_SEQUENCE
- ALIGNED\_DNA\_SEQUENCE
- ALIGNED\_RNA\_SEQUENCE
- ALIGNED\_AA\_SEQUENCE
- Type modifiers:
  - CASE\_SENSITIVE / CASE\_INSENSITIVE
  - FLC / IUPAC / ASCII
  - SHORT / DEFAULT / REFERENCE (only DNA)

# 3D数据处理(raster,pgpointcloud)

位置、RGB、密度、材质、。。。位点多元属性





3D打印是近几年兴起的一种技术，除了存储物体表面的位置信息，还有颜色，密度等信息。

而3D扫描其实在军用领域很早以前就有了。

# 一条SQL搞定聚类分析

- 一条SQL搞定聚类分析
- `SELECT kmeans(ARRAY[columns,...], K) OVER (...), * FROM samples;`




# 线性回归例子

- MADLib库(支持**几百**个机器学习库函数、对应**各种数学模型**)， PL/R, PL/Python
- 例子
  - p元线性回归
  - $y_1=b_0+b_1x_{11}+b_2x_{12}+\dots+b_px_{1p}+\epsilon_1$
  - $y_2=b_0+b_1x_{21}+b_2x_{22}+\dots+b_px_{2p}+\epsilon_2$
  - .....
  - 求截距，斜率。
  - 预测 $y_n$
  - $y_n=b_0+b_1x_{n1}+b_2x_{n2}+\dots+b_px_{np}+\epsilon_n$




```
linregr_train( source_table,  
out_table,  
dependent_varname,  
independent_varname,  
grouping_cols,  
heteroskedasticity_option  
)
```




# 机器学习UDF库

- SQL接口机器学习库MADLib (支持几百个机器学习库函数、对应各种数学模型), PL/R, PL/Python



# 一条SQL搞定流式实时处理

- 传统流式计算开发门槛高
- PostgreSQL 一条SQL搞定流式实时处理
  - 实时计算某WEB站点的请求延迟(**SLA实时监测**), 90%RT低于多少毫秒, 95%RT低于多少毫秒, 99%RT低于多少毫秒。
  - **实时营销**效果反馈 (实时检测某营销活动周边1公里的人流、车流)
  - 实时趋势**预测** (如股价, 温度, 湿度。。。)
  - 非流式处理的话, 响应时间在**十分钟级** (假设**十亿级**数据量)





# 超轻锁- 秒杀特性

- 超轻锁 (advisory LOCK) 解决高并发锁竞争问题
  - 手段: 在CPU运算发现行锁之前就知道是不是有冲突, 大大缩短CPU计算资源, 等待资源

## 传统 - 行锁弊端


1. 无效等待多
2. 无效等待用户  
长时间占用会话资源
3. 发现锁冲突的代码路径长  
需要进行大量CPU运算



# 数据库编程能力

- 数据库端函数编程
  - 支持 C, Python, R, perl, java, tcl, PHP, ... ..
- 解决move data带来的网络RT瓶颈

硬件发展迅速  
sharding后数据库IO、运算能力  
已经不再是瓶颈



# 数据库编程能力

TPC-C

新建订单 9 QUERY

支付 11 QUERY

订单状态查询 6 QUERY

发货 7 QUERY

对比20条QUERY(pk I,U,D,S)的事务TPS

1.交互式（业务逻辑在client完成）

2.服务端编程模式（业务逻辑封装在数据库FUNC完成）




万兆网络

64并发



TEST  
client






# 估值计算

- UV、新增用户数、TOP?
  - count(distinct)
    - sort, 去重, count
  - HLL
    - <https://github.com/aggregateknowledge/postgresql-hll>
    - 添加元素
      - hll\_add(set, hll\_hash\_integer(12345))
    - 获取选择性
      - hll\_cardinality(set)



# 物联网 - 旋转门压缩



# 议题

- PostgreSQL 前世今生
- PostgreSQL 社区理念
- 阿里云PostgreSQL内核优化

2016Postgres中国用户大会

JSON

HINT

GIS数据处理

多维分析

FDW数据泵

时序数据处理

异步消息

音频处理

立体几何

平面几何

基因处理

图数据处理

分词

旋转门压缩

数据走势预测

正则走索引

下棋

估值计算

探索宇宙

3D打印

GPU并行计算

流式计算

机器学习


文本挖掘

对接ES\Kafka\...

MR

LBS应用

一切皆可扩展 - 取自最终用户开源项目 (pgxn, github, pgfoundry, sourceforge, 社区.....)



### 历经43年进化 - 相当成熟的底盘技术

开放式接口

SQL兼容性

AGG\WINDOW

HOOK language handler

类型扩展(IO,OP,AM,FUNC)

FDW handler scan handler

支持数十种流行编程语言  
编写服务端函数

可靠性

扩展性

SQL-2013 递归查询 MVCC 优化器 8种索引方法,20种大类  
bt,hash,gin,brin,rum

ECPG 窗口查询 HASH JOIN 秒杀 bloom,gist,sp-gist

REDO  
流式复制  
多副本

块级增量备份&PITR

CPU并行计算  
读写分离  
水平分库  
多主同步

# PostgreSQL - 可编程数据库

传统数据库

能存取固定类型  
能用固定模式处理固定类型

传统数据库  
眼里

这是别墅



可编程数据库

能存取固定类型  
能用固定模式处理固定类型  
**能新增自定义类型**  
**能新增自定义数据处理和访问方法**

可编程数据库  
眼里

这是别墅  
同时允许扩展其用途  
迪斯尼  
农场  
赌场  
KTV  
银行  
超级市场  
医院

◦ ◦ ◦ ◦ ◦ ◦

# 继Ingres之后又一个改变世界的产品

- OLAP
  - Greenplum、AsterData、matrixDB、Paracle、Redshift、Illustra, Informix, Netezza、某些国产数据库。。
- OLTP
  - EDB、国家电网xxDB、某些国产数据库。。
- 云市场
  - ALL
- 流式数据库
  - pipelineDB
- NewSQL
  - Postgres-XL, Postgres-XC, Postgres-XZ, 。

2016 Postgres 国产数据库  
WHY?  
BSD-like 许可



Michael Stonebraker



[http://amturing.acm.org/stonebraker\\_1172121.pdf](http://amturing.acm.org/stonebraker_1172121.pdf)

[http://amturing.acm.org/award\\_winners/stonebraker\\_1172121.cfm](http://amturing.acm.org/award_winners/stonebraker_1172121.cfm)

[http://amturing.acm.org/vp/stonebraker\\_1172121.cfm](http://amturing.acm.org/vp/stonebraker_1172121.cfm)



# 议题

- PostgreSQL 前世今生
- PostgreSQL 社区理念
- 阿里云PostgreSQL内核优化

2016PostgreSQL中国用户大会

# 内核优化解决I/O hang的问题

- create database\clog\checkpoint



丝般顺滑

# oss\_ext解决大实例问题

- **透明冷热分离** 解决大实例问题

