QCon beijing 2011

吃蟹

视觉中国的MongoDB应用实践

插图: http://czone.chinavisual.com/art/4b4501548f47e8ef73699a0c.html

About.me

- 潘凡 (nightsailer) 视觉中国
  - @nightsailer //twitter,sina,linkedin, github ...
- nightsailer # gmail.com
- http://nightsailer.com/

为啥用MongoDB

赶NoSQL时髦?

Auto-shard等激动人心的特性?

- No! 08年，还都是浮云

最初的想法是寻找一个可靠的分布式K/V
解决MySQL的问题

原来的架构

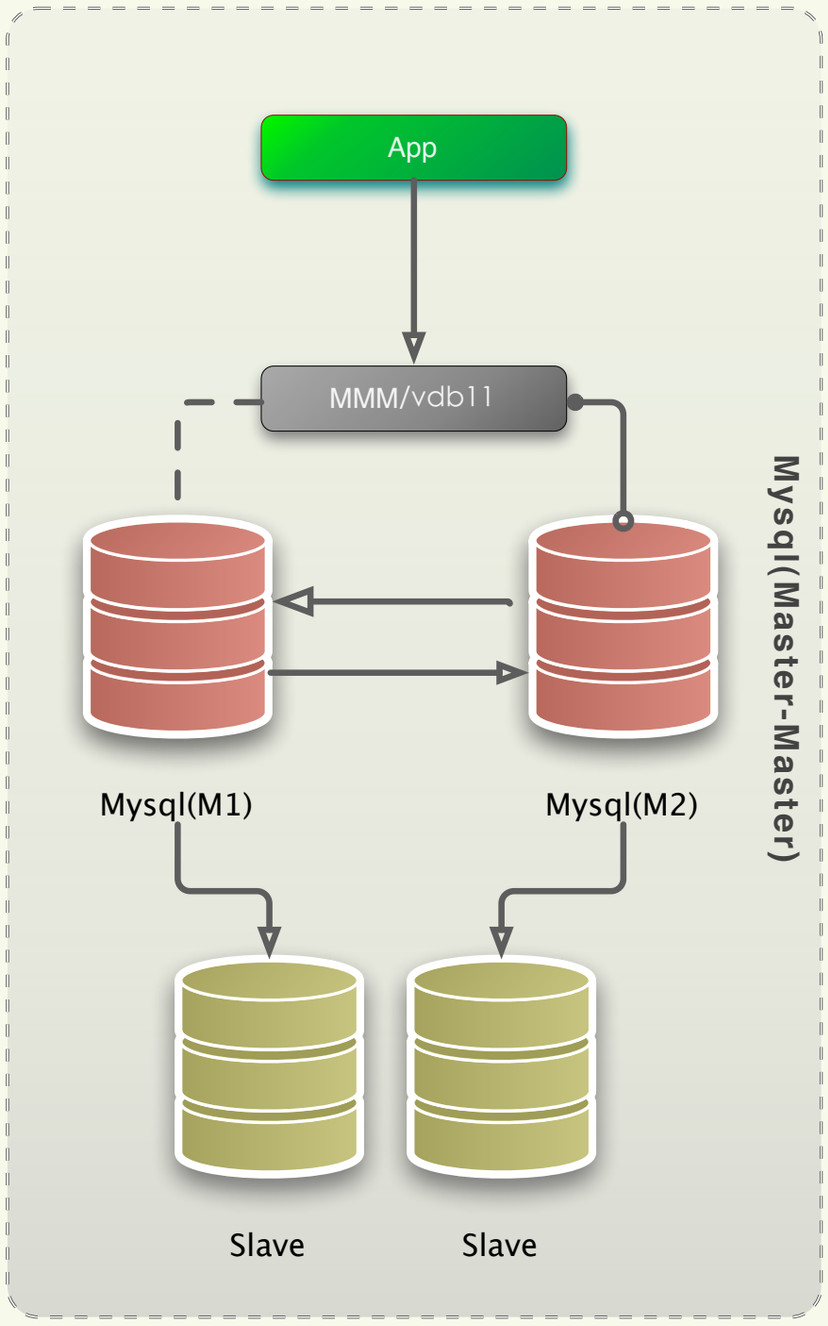

- MySQL（Percona），Master-Master-Slaves
- HA:MMM

新要求

- 能够适应多数据源
- 需要灵活，不确定的schema
  - 不同模型的字段不定，属性不定
- 属性更新频繁
- 服务器等硬件资源有限

如何解决?

原有MySQL的方案

* 使用文本字段，JSON存储
  - schema自由度高
  - 更新容易，直接检索困难
* 使用关联表
  - schema自由度有限，类型控制
  - 更新频繁，query缓存失效

新思路

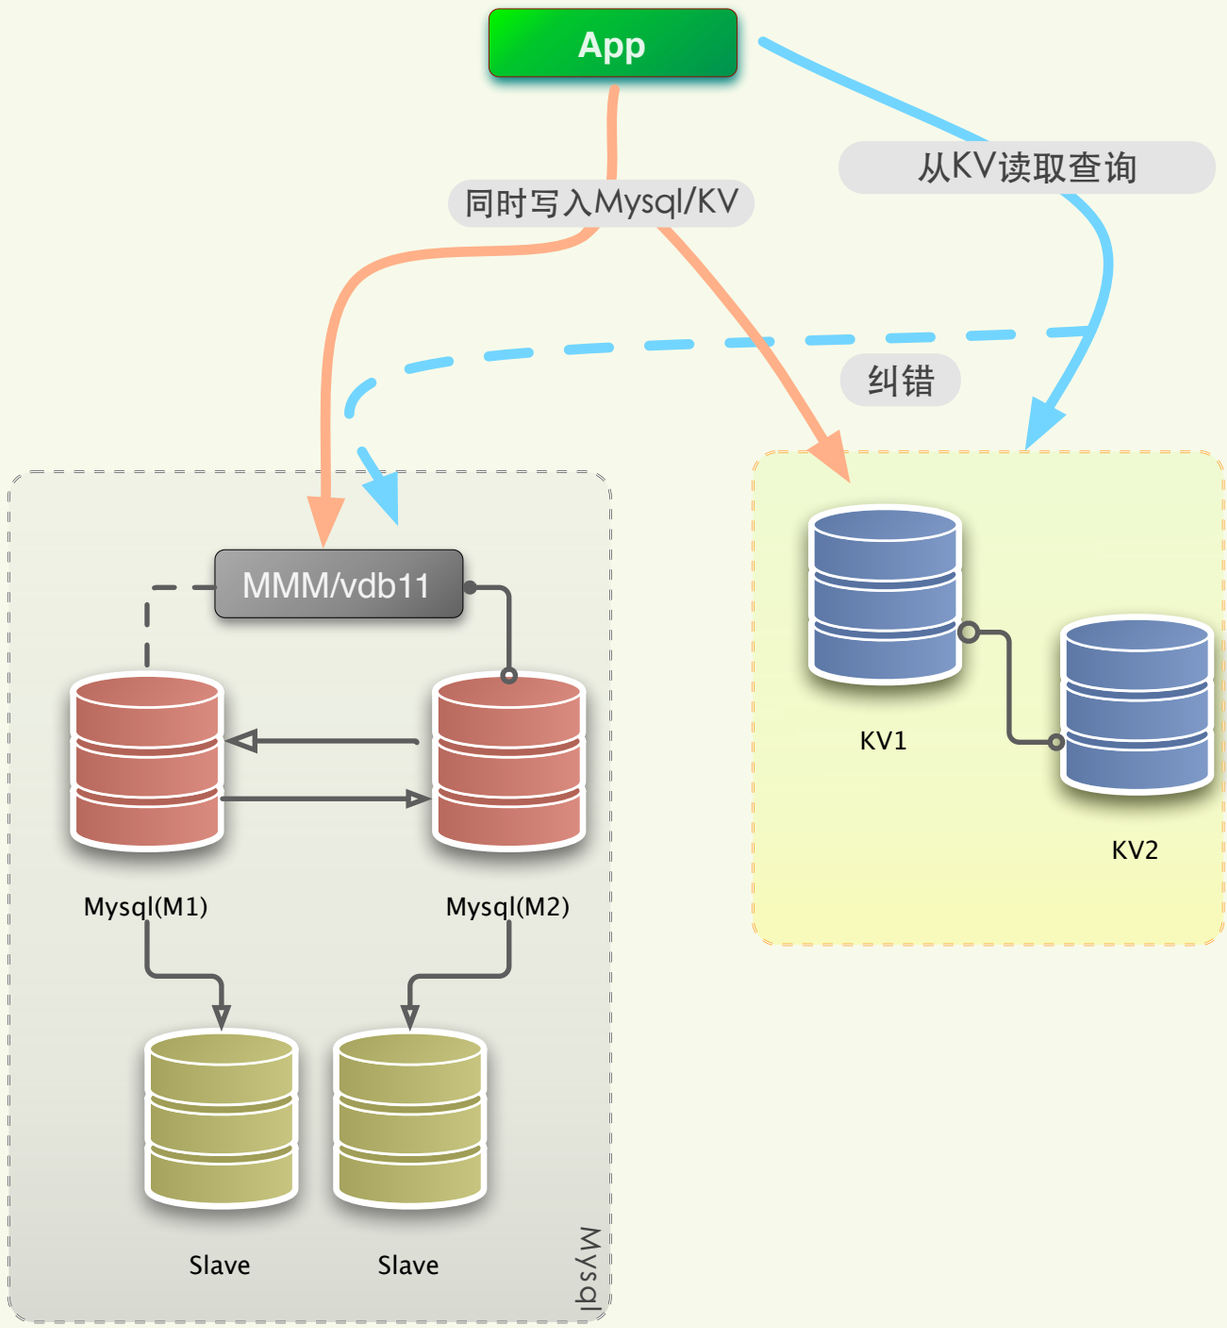
App
同时写入Mysql/KV
从KV读取查询
纠错
MMM/vdb11
Mysql(M1)
Mysql(M2)
Slave
Slave
Mysql
KV1
KV2

新思路

继续使用Memcached?

- 缓存失效，内存不足

决定：寻找Memcached替代品

- 能够持久化的分布式KV

选型条件

- 同时有PHP/Perl的良好客户端支持
- 性能和Memcached相差不要太多
- 支持分布式集群
- 低碳环保，节约资源
- 文档清晰，有成功案例

一些候选者

- Flare
- Repcached
- Redis
- TC/TT

最初的选择

选中Flare

- 内置cluster看起来很美好,可靠性有保证
- 使用Memcached协议，现有改动小

代价

项目开发1个月后

- 官方更新显示似乎并非如此可靠
- 水土不服:
  - 个人能力有限，无法解决一些灵异事件
  - 没有开发者社区
  - 不懂日文 ;-(

新的候选者

- Cassandra
  - 技术实力无法支撑，用不起
- CouchDB
  - 灵活，但性能口碑似乎不佳

重新选择

MongoDB

- 读写性能中庸，比Redis逊色
- Document模型令人满意
- 内置操作没有Redis惊喜，基本够用
- MySQL类似的集群机制,上手方便
- 某些MySQL的优化部署经验可以复用

胆子再大一点

MySQL + MongoDB?

- 多余：很多MySQL的操作MongoDB均可实现
- 同时维护 MySQL <=> MongoDB 的数据，代码逻辑有些复杂
- 人员流失，培训新人表示鸭梨大

胆子再大一点

能否彻底抛弃MySQL

- Transaction？可以没有
- Joins？ 原本少用，可以没有
- 数据一致性：不太高

胆子再大一点

好吧，试试

- 拿一个旧项目开刀
- 1人1个星期完成90%代码移植
- 原有35个table => 10 collection
- 开发过程很happy!

MongoDB,就是它了

一举两得的加分项： GridFS

- 简单，符合我们的要求
- 无需再考虑分布文件系统
  - 放弃了原来的MogileFS，减轻运维压力

MongoDB,就是它了

选对了

- SourceForge等一些大站应用增强信心
- 分享的信息逐渐丰富
- 10gen核心团队在mailing-list快速响应，有问必答
- NoSQL开始受到追捧，MongoDB的口碑良好

应用案例I

- 评论


```
comments:{
   _id:ObjectId(‘xxx’),
   art_id:2,
   content: ‘呼呼 真是...’,
   replied_on:  12233
   created_on: 12222
   replies: [{
      _id: ObjectId(‘xxx’),
      content: ‘哈哈,谢了...’,
      replies:[]
   }]}
```

应用案例2

用户动态/新鲜事:

- 关注的用户的动态
- 个人作品的新动态
- 关注的作品的新动态（评论过/收藏过/打分过...)
- 可取消对特定事件的订阅

应用案例2

推送模式的实现

- db.activity_stream.feed (订阅事件）
- db.activity_stream.user（用户动态汇总)
- db.activity_stream(动态详细信息）

应用案例2

feed的优化

- 区分热门用户和普通用户
  - 热门用户的follower使用独立的collection
  - 普通用户使用embed list

应用案例3:全文检索

尝试1: Regex

- 无索引，慢!

尝试2: Sphinx

- 手动生成xml，刷新重建索引
- 无法增量索引

应用案例3:全文检索

尝试3: 分词 + Array/List 查询($all)

- 简单，够用
- 分词：PHP-SCWS（谢谢！）
- 增量索引:
  - 无侵入索引过程：从oplog读取，解放应用端

准备部署

手动编译MongoDB

- Scons, 要懂点Python
- 升级boost(CentOS)
- static link mongod
- 使用tcmalloc

准备部署

- 手动编译MongoDB(ICC编译选项)

```
COMMON_CXXFLAGS='-fp-model source -unroll2  -axSSE4.1,SSE4.2 -xSSE3 -
static-intel  -fpic  -fno-strict-aliasing'

CXXFLAGS="-O3 -ipo  -static-libgcc $COMMON_CXXFLAGS"

scons --release --static --extrapath=/opt/local  --cxx=$CXX --icc --
extralib='tcmalloc_minimal' --icc-cxxflags="$CXXFLAGS" --icc-
cppflags="$CPPFLAGS"  -c $BIN_SERVER

scons -j4 --release --static --extrapath=/opt/local  --cxx=$CXX --icc
--extralib='tcmalloc_minimal' --icc-cxxflags="$CXXFLAGS" --icc-
cppflags="$CPPFLAGS" $BIN_SERVER
```

准备部署

- 定制编译麻烦，但是相对稳定，问题很少（不仅仅是心理安慰）
- 缺点：无法及时更新编译，只针对性的升级

准备部署

- 磁盘： 使用Raid10
- 文件系统：
  - XFS
  - Ext4 (?)

部署

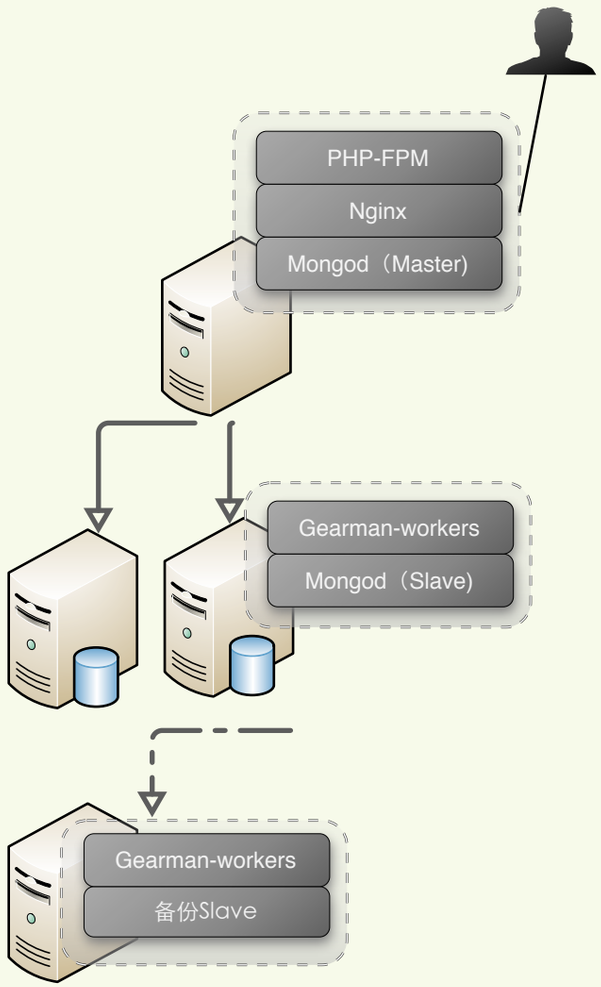

开始，2009/6, 版本： 0.9/1.0

- 1 Master + 2 slaves
- 1m 初始数据
- 20g存储
- Dell 2850/4g(Master) + 2*Dell 2950/4g(公用）

备份

* 使用独立Slave方式备份
  - 慢，不影响
* lvm snapshot
  - 快，客户端瞬时无法写
  - fsync & lock db
* mongodump?
  - 速度慢 + 空间浪费 + 恢复慢

监控

- mongostat / vmstat / iostat
- collectd（我们使用这个）
  - 自定义: json-rest+perl plugin
- 其他： Munion / Nagios ...

美好的时光

MongoDB不是重口味

- CPU友好，几乎无负担
- 内存需要足够放下索引，4G以上为佳
- 可以和磁盘IO不高的应用混搭

插图:http://czone.chinavisual.com/art/4c7918b74979590970b80000.html

美好的时光都是短暂的，6个月后

开始有点问题了

插图:http://czone.chinavisual.com/art/4b45015496ddabef73f49197.html

故障0:开发版的血案

* MongoDB 宕机
  - Out of Memory!
  - 新版本v1.3某些情况出现内存泄露
* 服务端cursor过多
  - Perl driver的bug, 修复

故障0:开发版的血案

教训1:

- 永远别用开发版，即使天大的诱惑
- 谨慎使用稳定版的头2个小版本

教训2:

- 选用了一个语言，团队内就要有人熟悉对应的driver代码
- 自己实现一个driver是个不错的想法

故障1:50x的烦恼

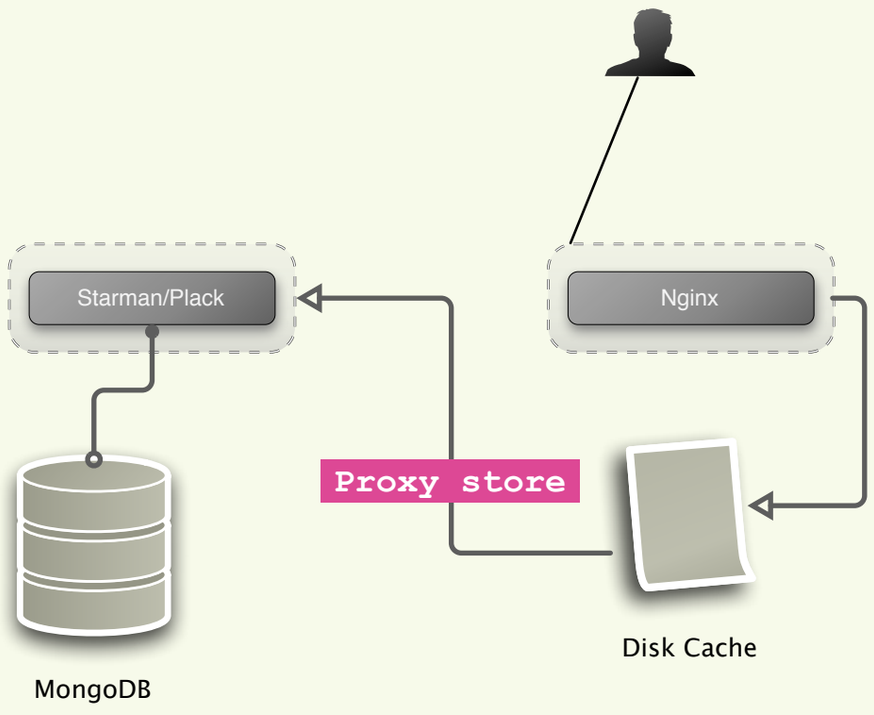

502 Bad Gateway

* GridFS的问题?
  - 使用Perl Plack替换 = 》好转

* 减少GridFS的读取
  - Nginx proxy_store
    - 不是最优，但简单，够用

故障1:50x的烦恼

504 Gateway timeout

- 灵异：开发环境无法重现
- 无规律，白天或晚上均会出现
- Perl救场：根据nginx_errorlog的时间抽取前后5分钟内mongodb.log日志
- 找到元凶：空间分配延时导致client端超时

故障1:50x的烦恼

教训3

- 使用XFS等支持pre-allocation的FS
- 提前预分配数据文件:

```
for i in {1..50}
do
    echo $i
    head -c 2146435072 /dev/zero > $db.$i
done
```

故障2: 空间使用

- Mongod crash
- 磁盘空间不足， Why?
  - 应用执行操作： Map/Reduce删除/重新插入
  - 删除空间不能回收

第一次灾难

- 机房电源空开跳闸
  - 10台服务器全部遇难
- MongoDB无法启动
  - 尝试Repair～5小时后失败
  - 从备份中恢复
  - 丢失了10小时数据！！

插图来自：http://czone.chinavisual.com/art/4cad0e08497959d621a10000.html

第一次灾难

- MongoDB的致命缺陷：
- 单机可靠性低
- cluster可靠性: 通过slave复制保证
- 部署时没有考虑机房断电的特殊情况

亡羊补牢之I

- 缩短磁盘刷新间隔 --syndelay
  - 60s(default) => 15~30s
  - 磁盘IO受到影响，可接受
- 应用端批量写入后调用fsync
  - 写入速度降低

亡羊补牢之2

- 升级到1.6.3,转换Master-Slaves到RelicaSets
  - 1 Primary + 2 Secondary
- 服务器升级到4g-8g内存
- 应用端同时使用w=2参数
  - 写入速度降低

教训5

- 我们很业余
- 安全第一
- 要考虑极端条件下的容灾和数据安全
- 完整的离线备份总是你最后的救命稻草

然而，还没有结束。。。。

插图:http://czone.chinavisual.com/art/4bd19d3b4979593e1a350000.html

故障4: RS fail-over失效

- MongoDB 不可用
- Primary维护期间不小心kill了第2个secondary
- 剩余的secondary未能正常接管

故障4: RS fail-over失效

解决:

- 增加2个 Arbitor
  - $ mongod --bind_ip 127.0.0.1,192.168.8.10 --replSet rs10 --oplogSize 1 ...
  - > rs.addArb('192.168.8.10:27020')
  - ...

故障4: RS fail-over失效

教训6: 这才是完整的ReplicaSet

- 1 Primary + 2 Secondary + n Arbitor
- 文档中语焉不详的往往是你最被忽视的，把它搞清楚
- 避免手动维护，使用事先写好的脚本

又一次断电了！

- 6个月后，“又”一次出现断电
  - 这次是修空调拉错闸 ;-(
  - 临时工不好当
- 重启后，ReplicaSet集群fail-over到一个secondary，中间过程无干预
- Primary 无法启动,仍需要修复！
  - 还好！

1.8的改进

- 1.8提高了单机可靠性的一个措施
  - journaling file
  - mongod -dur
  - 避免crash后必须repairDatabase
- 初步测试，效果尚可，准备稳定后升级

有了新需求

- GridFS的新需求
  - 能够存储较大文件（高清图片，压缩包）10mb-500mb不等
  - 允许用户使用多线程下载

问题

- GridFS大文件的分发
  - 不能使用Nginx proxy_store加速
- MongoDB读取负担加大
- 并发链接增加,Plack app响应速度下降
  - prefork模式有限制

措施

- GridFS文件分库
  - 缩略图，高清图片 + 大文件
- 读写分离（slaveOK）
- 将Plack app部署到Twiggy（AnyEvent），解决高并发链接的问题

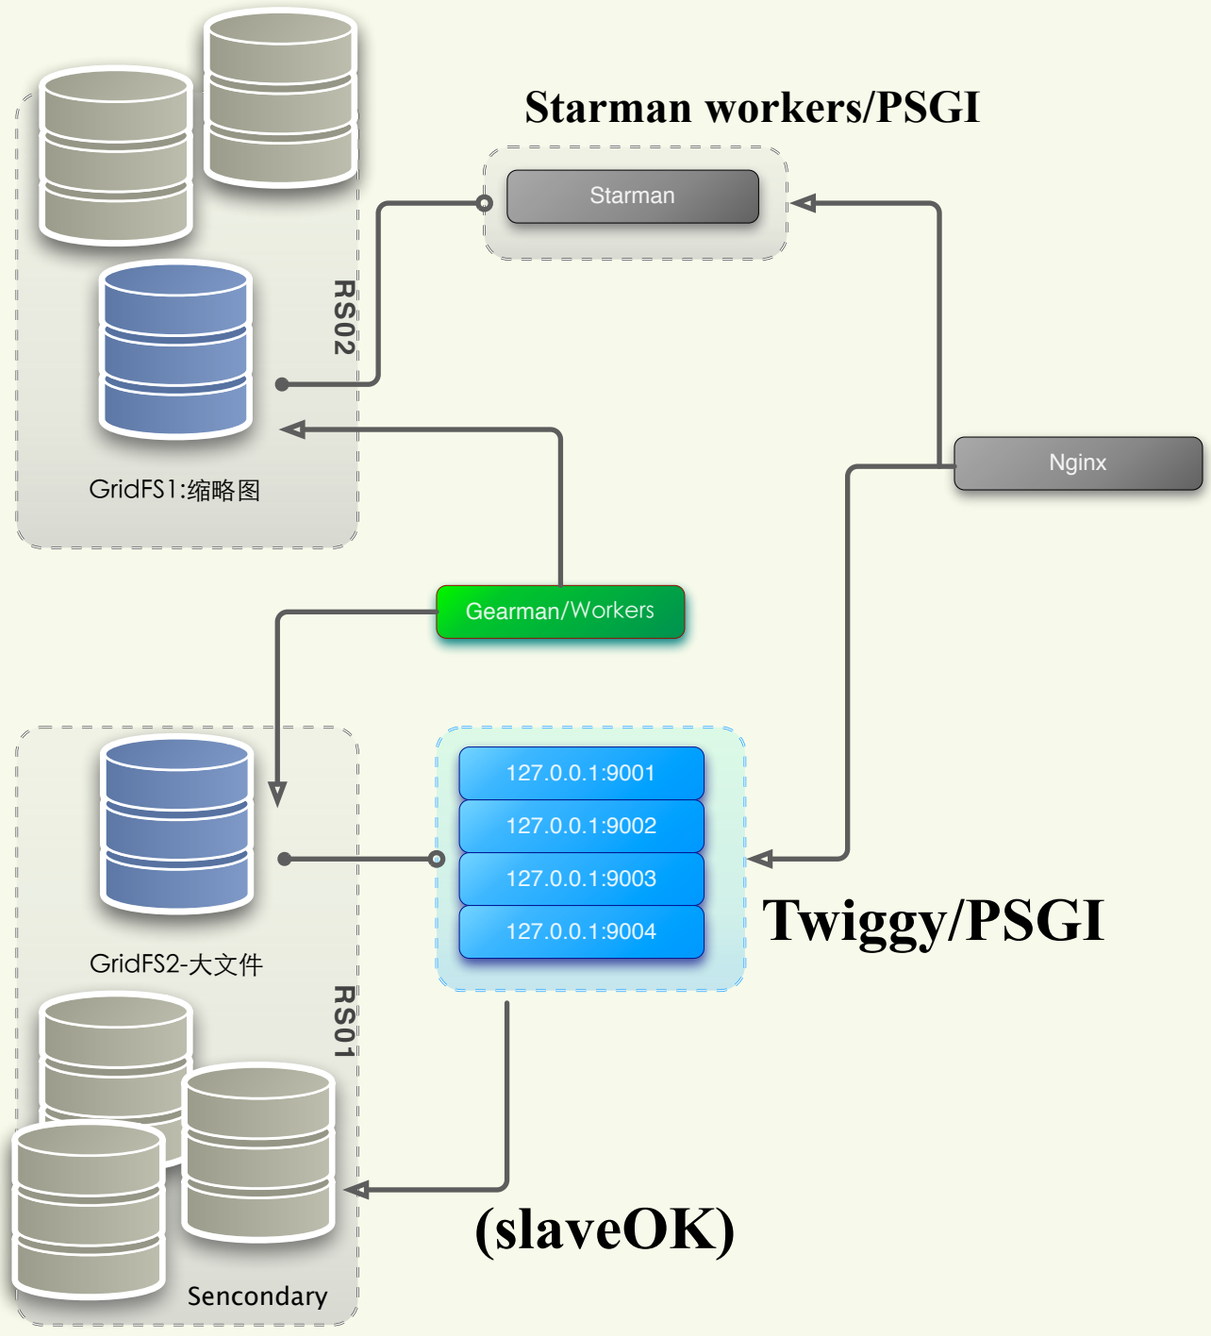
Starman workers/PSGI
Starman
RS02
GridFS1:缩略图
Nginx
Gearman/Workers
127.0.0.1:9001
127.0.0.1:9002
127.0.0.1:9003
127.0.0.1:9004
Twiggy/PSGI
GridFS2-大文件
RS01
Sencondary
(slaveOK)

带宽不够用了

- 下载太消耗带宽
- 国外的服务器和带宽都便宜
- 怎么同步?

理想

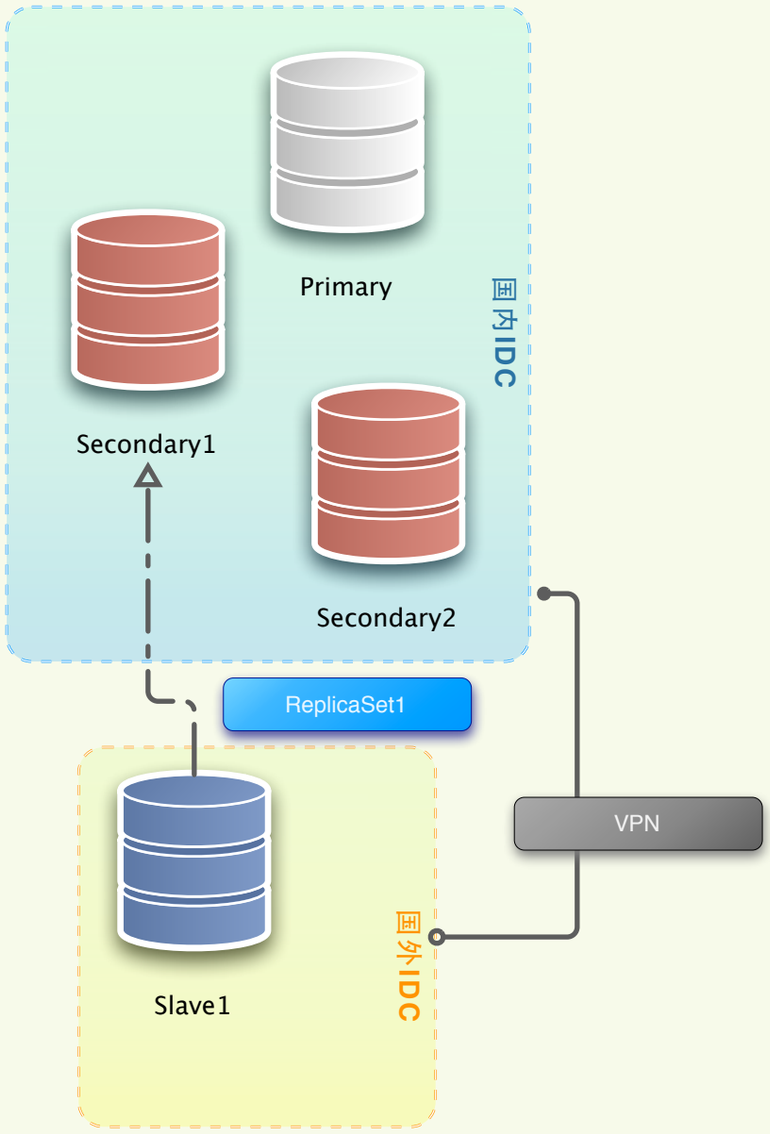

- 国外使用一个Slave only的MongoD节点
  - priority = 0
- VPN链接2个数据中心

现实

- 超高的网络延时 >300ms
  - MongoDB 启动失败，无法完成初始化

折腾

- 解决MongoDB延迟启动
  - 将snapshot手动复制到国外
- 手动作复制工作
  - 监控local.oplog.rs (使用tailable cursor)
  - 压缩后发送到国外节点
  - 接收端接收后replay oplog

失败！

- 运行了2个月，暴露的问题：
  - GridFS数据传输较大，复制延迟时间较高
  - 墙让VPN不时抽风

调整

- 放弃集群和VPN
- 将GridFS本地导出压缩后传送到国外
- 仅仅将需要更新的数据更新到国外
  - BSON压缩，使用HTTP协议 + 多点续传
- 国外使用普通的mongod

教训7

- 小心陷入思维定式
  - 太华丽 = = 不现实
  - 不要忽视最土鳖的做法
- 灵活运用不同的unix工具

插图: http://czone.chinavisual.com/art/4c05e7be4979596b7e570000.html

Auto-sharding

- 1.6GA 内置了Auto-sharding
  - 有诱惑，尝试
- 2套方案并行1个月
  - 从原有生产系统导入数据
  - 并行写入测试集群

测试结果

- Shard_key的烦恼
  - 单一shard key导致chunk分配不均衡
    - 类似4sq案例
  - 复合shard_key需要修改现有的应用端
- counting 不准
  - 务必减少chunk的移动
- balancer的稳定性，也不够智能

测试结果

- 结论：
  - 从现有非shard环境升迁是很痛苦的过程
  - 如果最初就是shard，相对容易
- 维持现有的手动分片机制
- 等待1.8成熟，新项目可以考虑使用

无责任小结

- 市场宣传亮点和实际会有差距
- MongoDB的auto-shard目标感觉很好
- GA和完全成熟可靠多少还有些差距
  - 2.0+ ?

MongoDB其他小结

- 多数MySQL的Web应用均能胜任
- Schema free，大大提升开发效率
- Geo搜索降低位置服务门槛
- MySQL优化的一些经验可以复用
- GridFS能够胜任中小规模的文件系统
- 千万级别的数据量完全无需做sharding
- Auto-sharding注意shared_key和balancing的过程，建议1.8/2.0以后使用

这些也许有用

- mongostat
  - idx missing, faults,global locked
  - db.serverStatus & rs.status

这些也许有用

- Replication
  - 手动指定oplogsize //大数据同步，避免slave无法clone
  - --fastsync + snapshot 快速同步
  - --maxConns
  - --replSet=<set_name>/<seed list>
    - seed list至少包含1个arbitor

这些也许有用

- Some collections
  - local.oplog.rs/replset.minvalid
  - $cmd
  - system.indexes

这些也许有用

- GridFS
  - 推荐模式:Write once, Read many.
  - 使用fs.files _id 做ETag
  - 基于file content hash做引用计数
  - 定期gc
  - * Node.js 值得关注

这些也许有用

- Update/Delete
  - 频繁更新,Schema已知可做padding
    - In-place update友好
  - Mark delete，定期定量remove
    - 减少不可用碎片
  - 不要remove() , 直接drop

这些也许有用

- Group
  - 4Mb 限制，用MR替代
- db.eval & Javascript
  - 谨慎使用， 单线程，阻塞db
  - 注意安全！务必使用scope传递参数，勿直接用字符串变量构造
  - 实现副产品：模拟单机原子操作

这些也许有用

- DBRef
  - 过时，不要用
- MR
  - 单机单线程
  - 尽可能只在后台服务使用，前台直接使用MR处理的结果，勿实时调用
    - v8不会显著提升性能

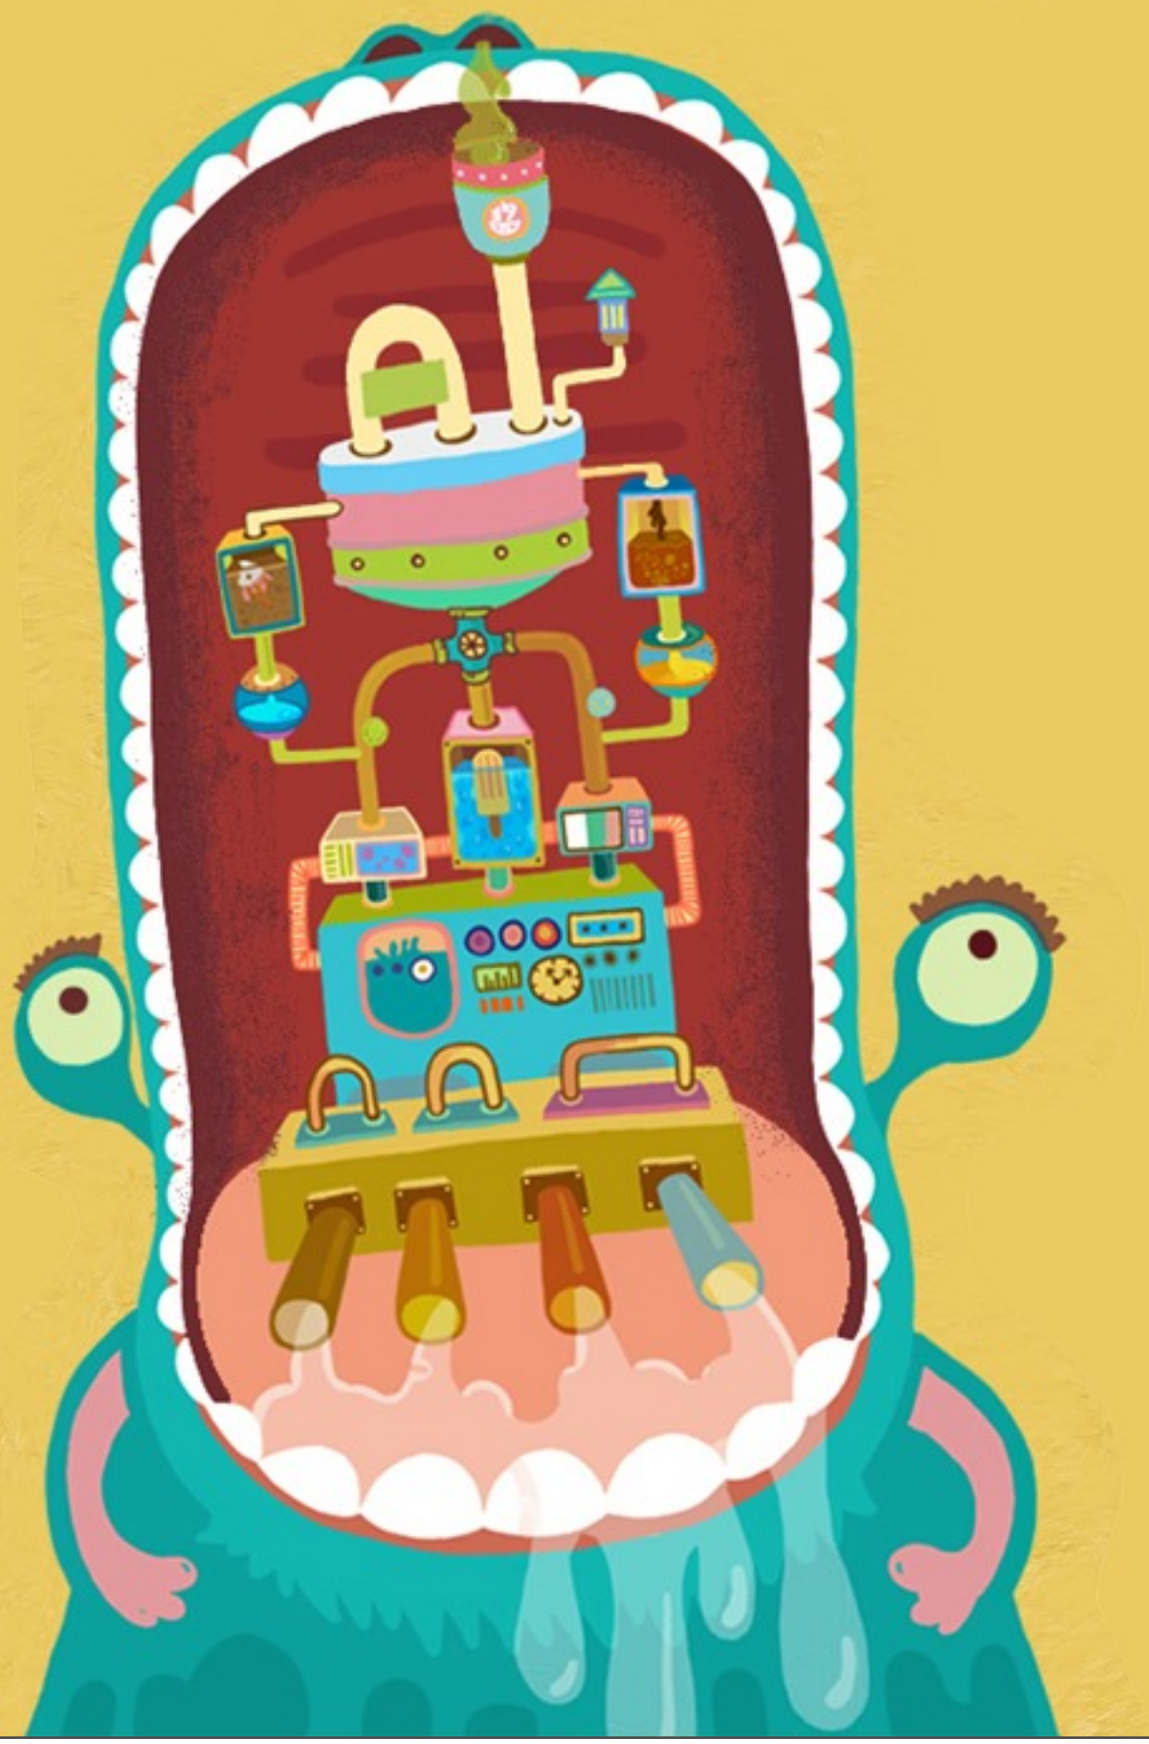

Question?

谢谢大家！

插图来自:http://czone.chinavisual.com/art/4b45015461be3def730e6351.html