打造58千亿级分布式存储平台

江军平

关于我

58集团基础架构部 技术总监

- 分布式存储平台
- 分布式缓存平台
- 微服务框架及支撑平台
- IM即时通信平台
- 核心基础服务

腾讯高级架构师

- 微博&微视&视频后端技术负责人

微软STC研发工程师

@stevejiang

Agenda

存储架构的痛点和挑战

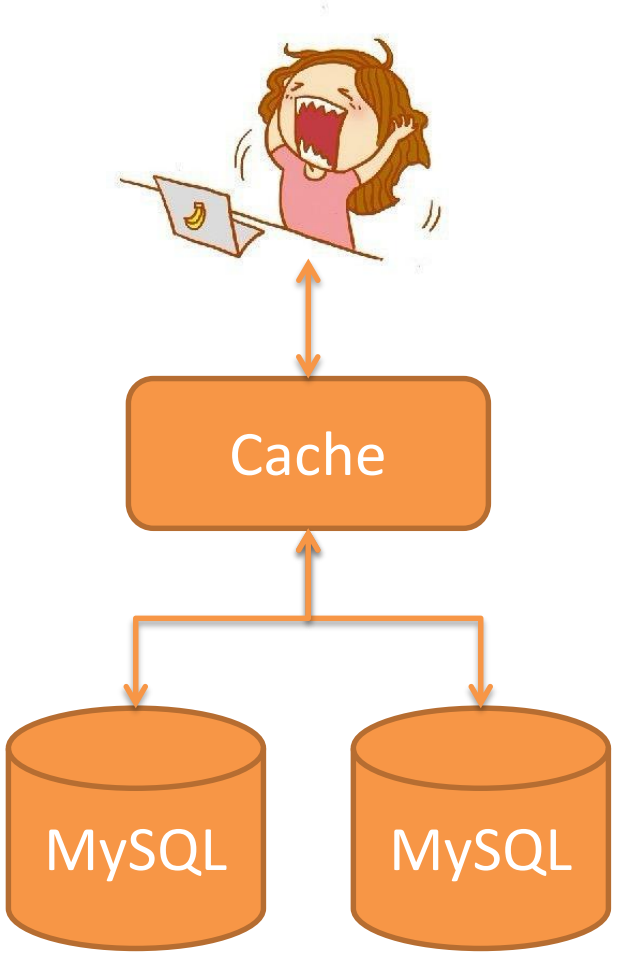

扩容

性能

扩展性

可用性

规模

- 爆炸式增长

团队

- 小团队 → 超大团队

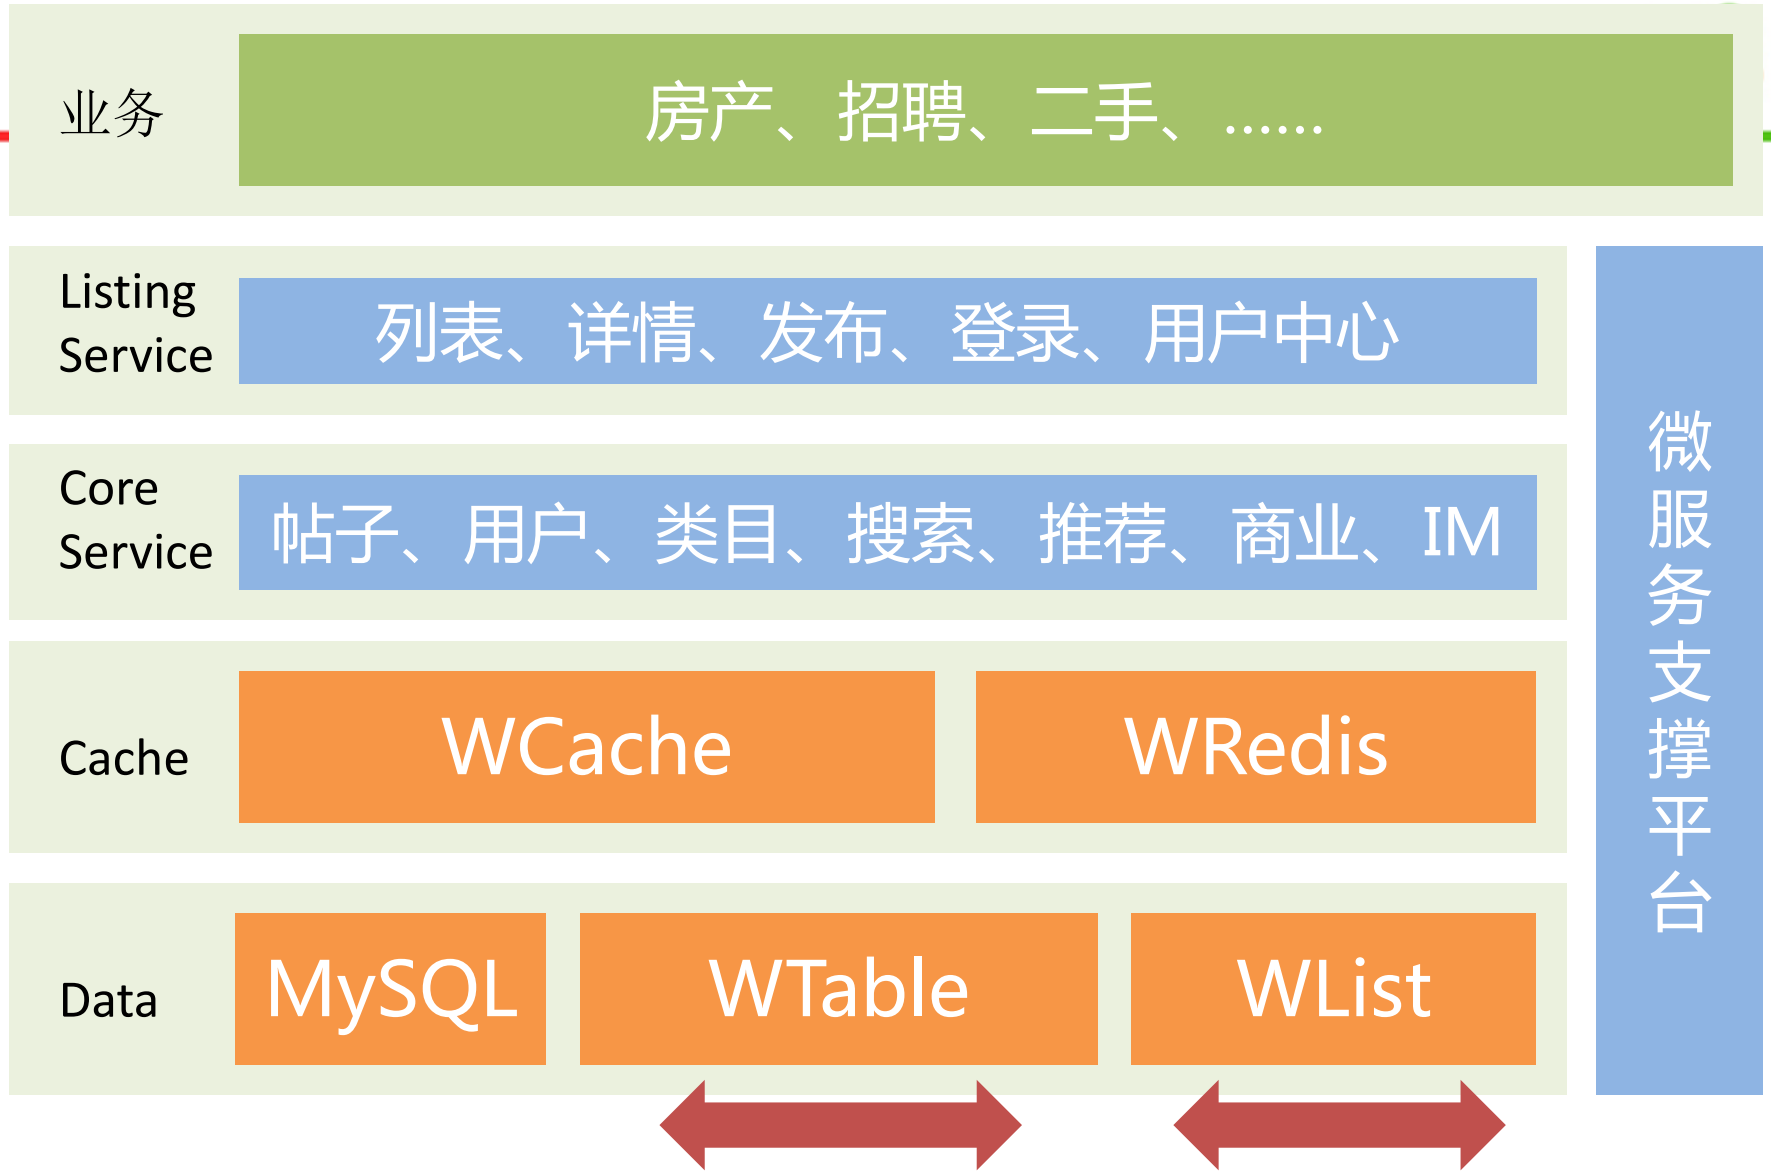
业务
房产、招聘、二手、……
Listing Service
列表、详情、发布、登录、用户中心
Core Service
帖子、用户、类目、搜索、推荐、商业、IM
Cache
WCache
WRedis
Data
MySQL
WTable
WList
微服务支撑平台

WTable分布式存储平台

让 生 活 更 简 单

58自研 + 分布式 + NoSQL

Key-Value

- {rowKey,colKey} → {value,score}

Key-List

- 按colKey排序，按score排序

	colKey1	colKey2	colKey3	…
rowKey1	value, score	value, score	value, score	…
rowKey2	value, score	value, score	value, score	…
…	…	…	…	…

WTable的规模

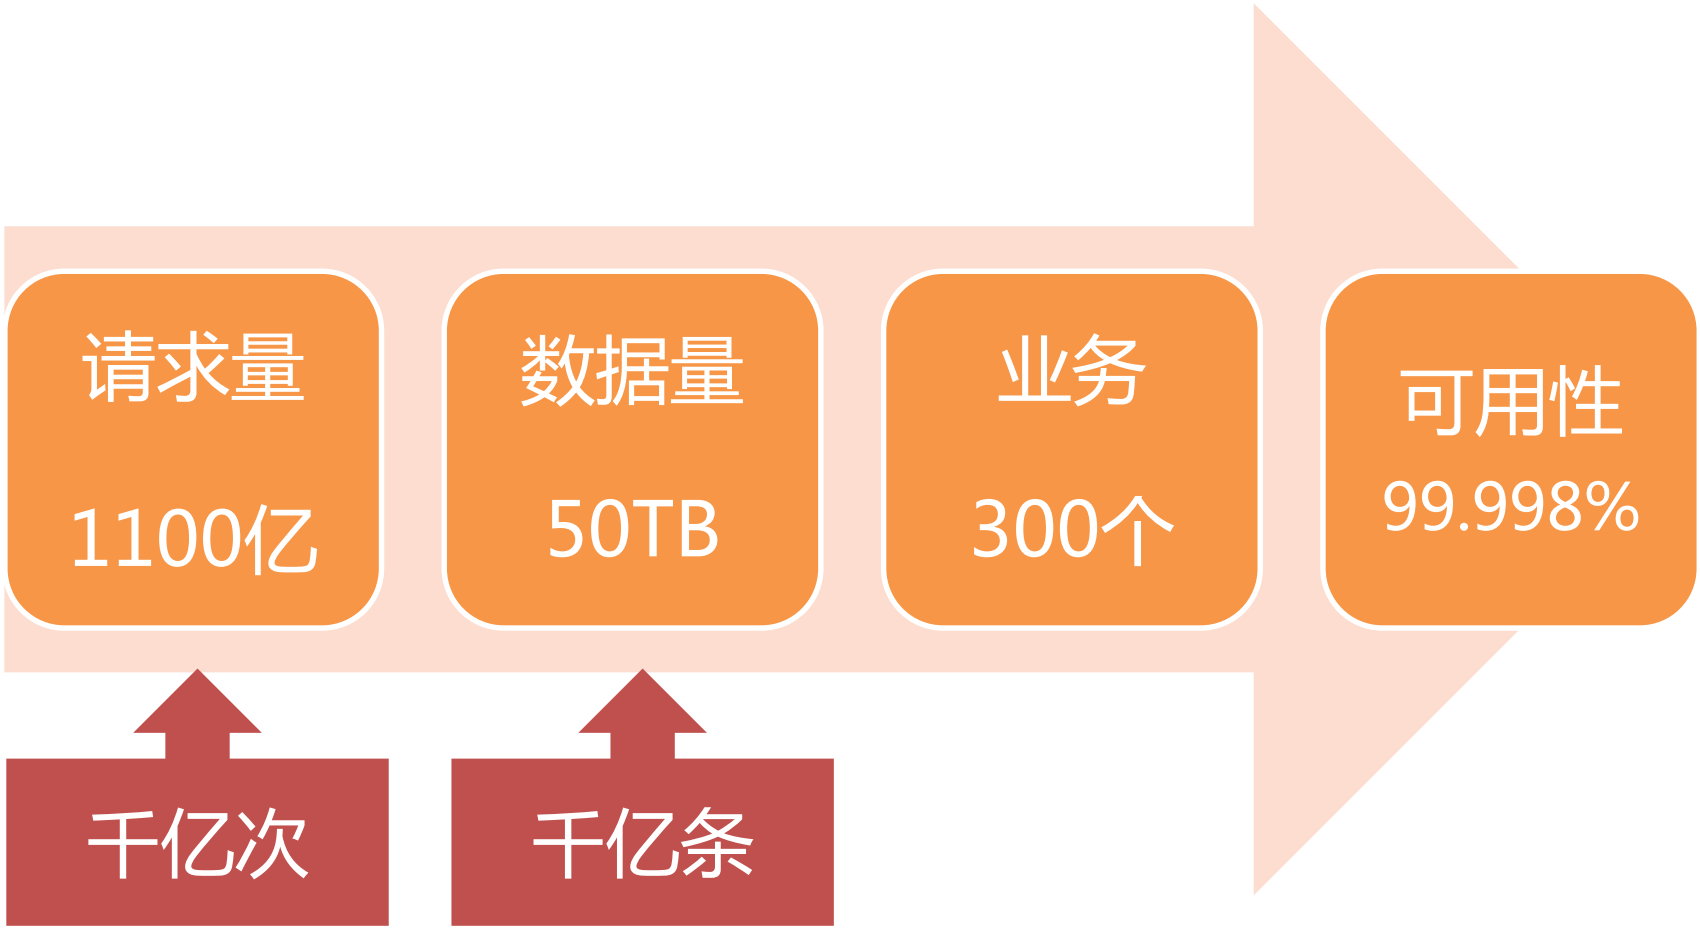

WTable关键技术

1. 整体架构

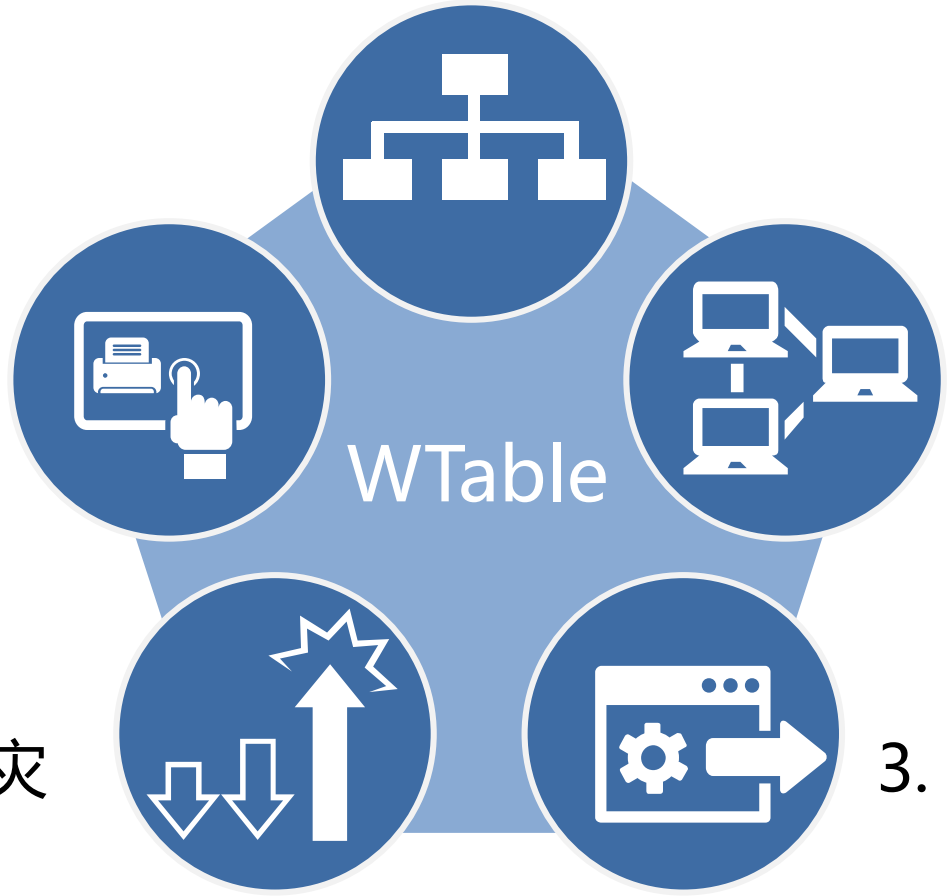

2. 主从同步

3. 横向扩容

4. 容灾

5. 监控告警

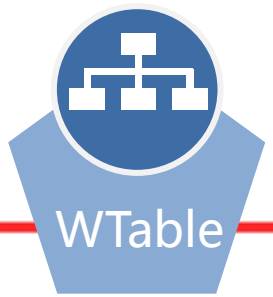
WTable

1. 整体架构

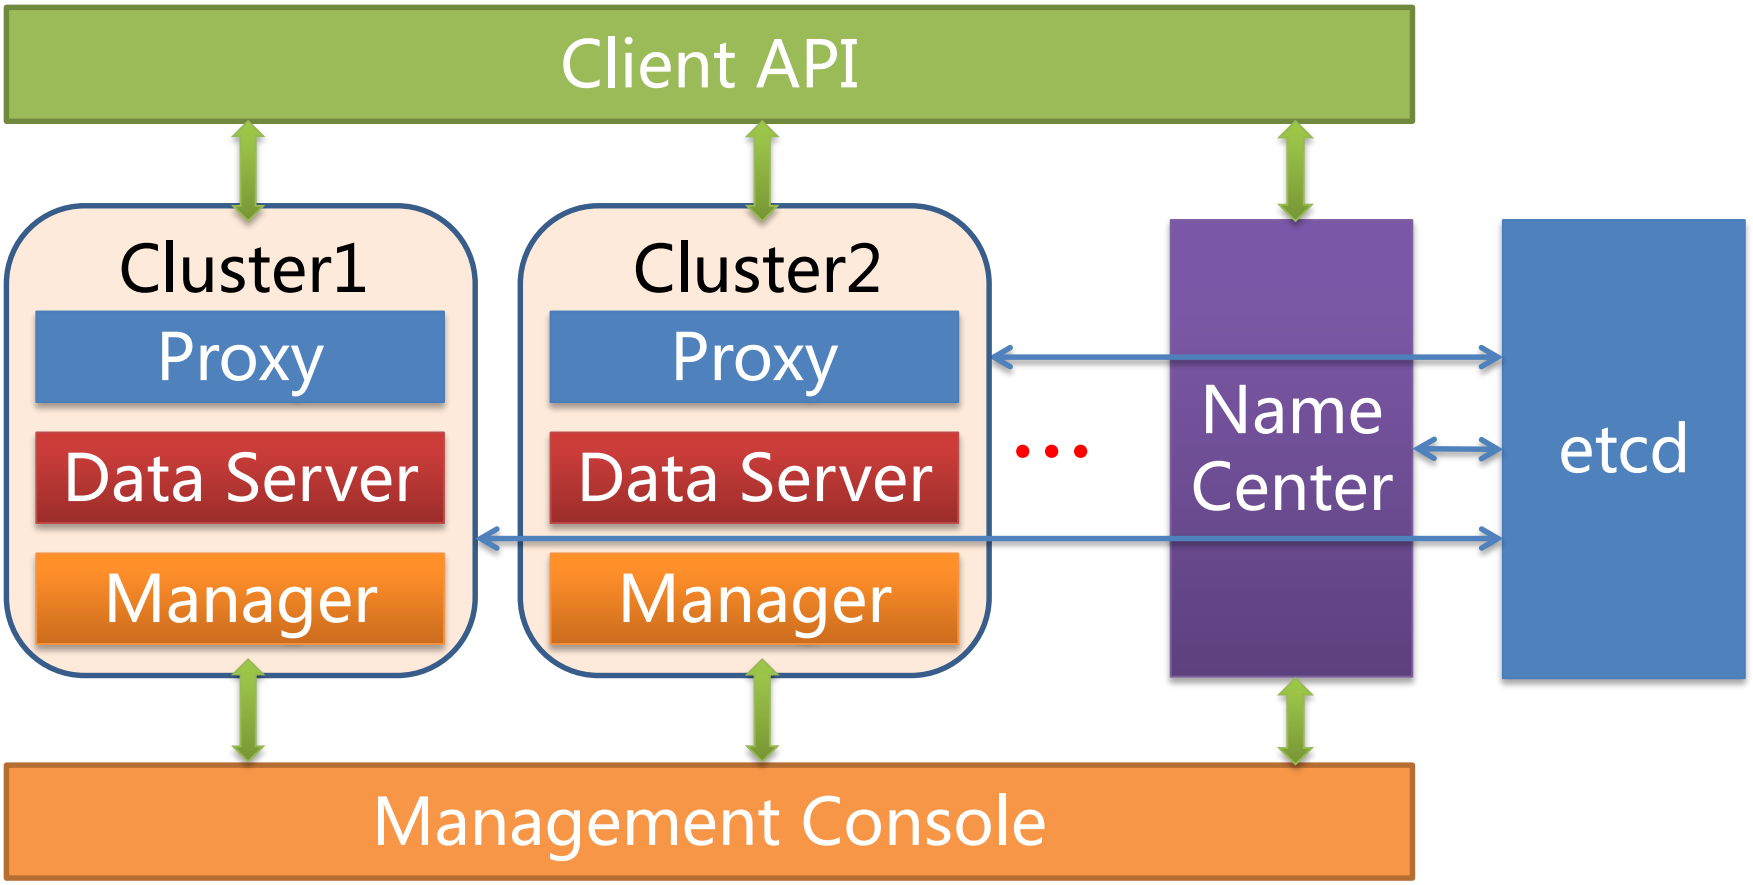
Client API
Cluster1
Proxy
Data Server
Manager
Cluster2
Proxy
Data Server
Manager
...
Name Center
etcd
Management Console

1

隔离 + 共享

- 大集群？
- 小集群？
- 混合模式

2

Proxy + 多一层

- 客户端变简单
- 更好容灾
- 并行处理

3

引擎 + 性能

- BerkeleyDB ?
- LevelDB ?
- RocksDB

4

逻辑层 + 效率

- C/C++
- Golang

2. 主从同步

异步实时推送

- 不一致风险
- 毫秒延迟
- 高性能+高可用

半同步复制

- 一致性强
- 写性能下降
- 可用性下降

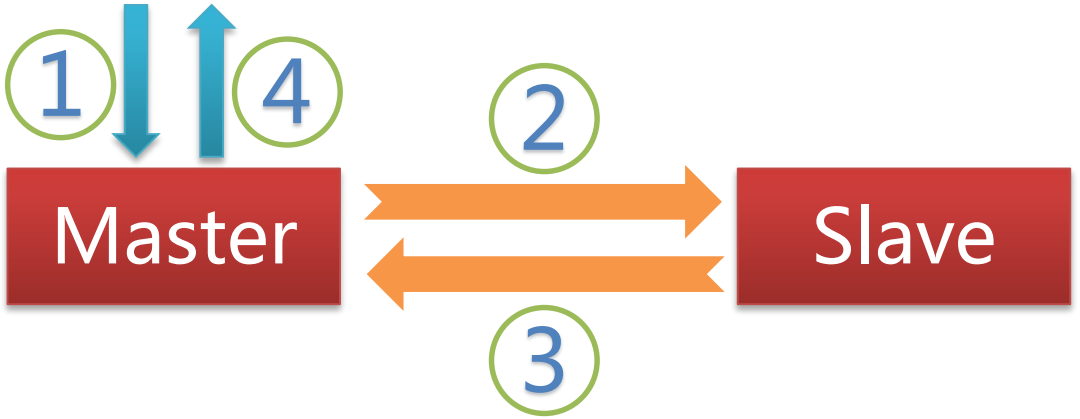

3. 横向扩容

逻辑层 + 数据层 + 配置

Key-Value	• {rowKey,colKey} → {value,score}
数据分片	• rowKey → slot

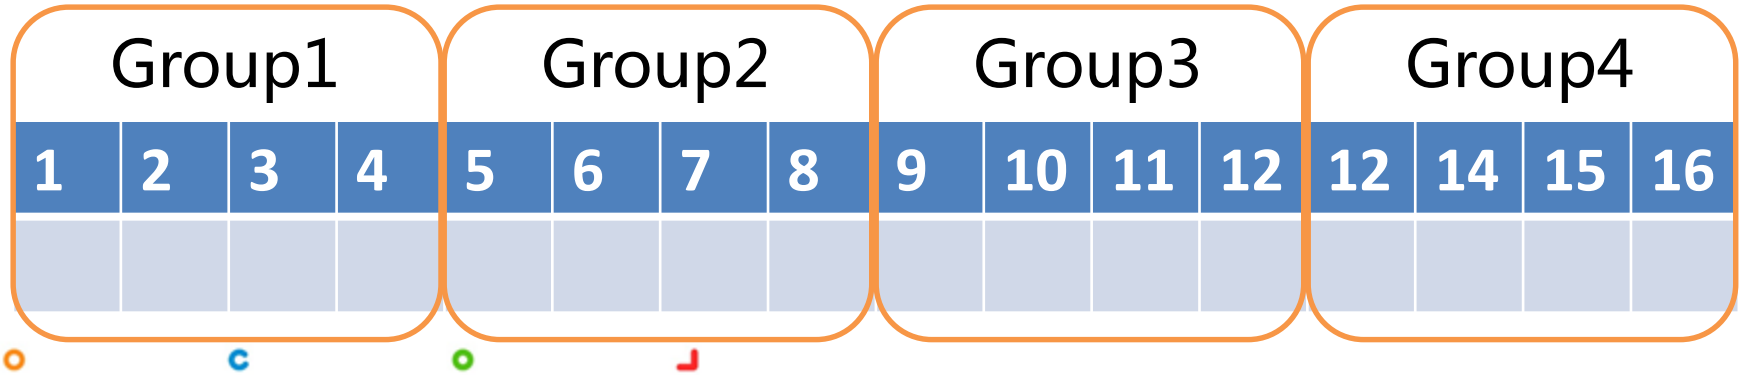

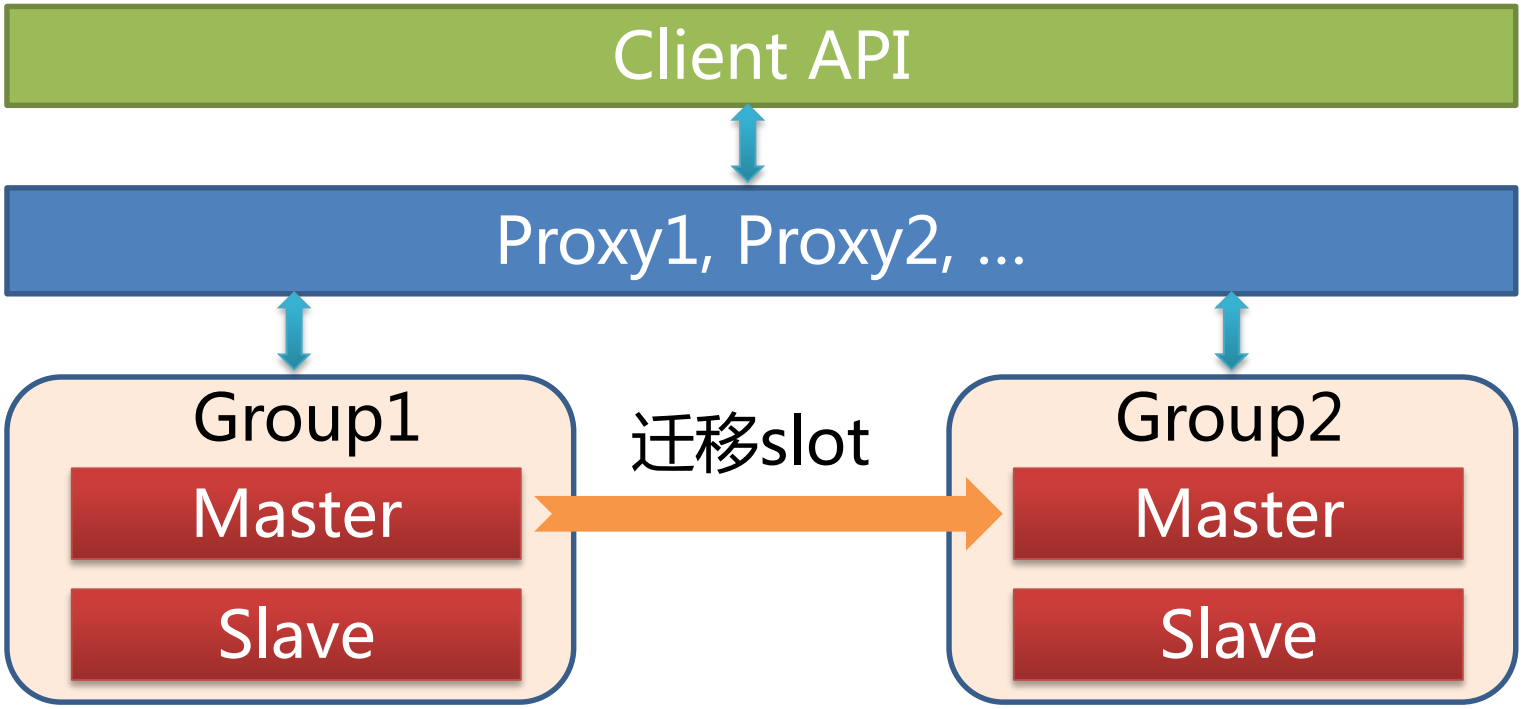

一键扩容

自动控制 → 主从同步 → 推送配置 → 确认完成

4. 容灾

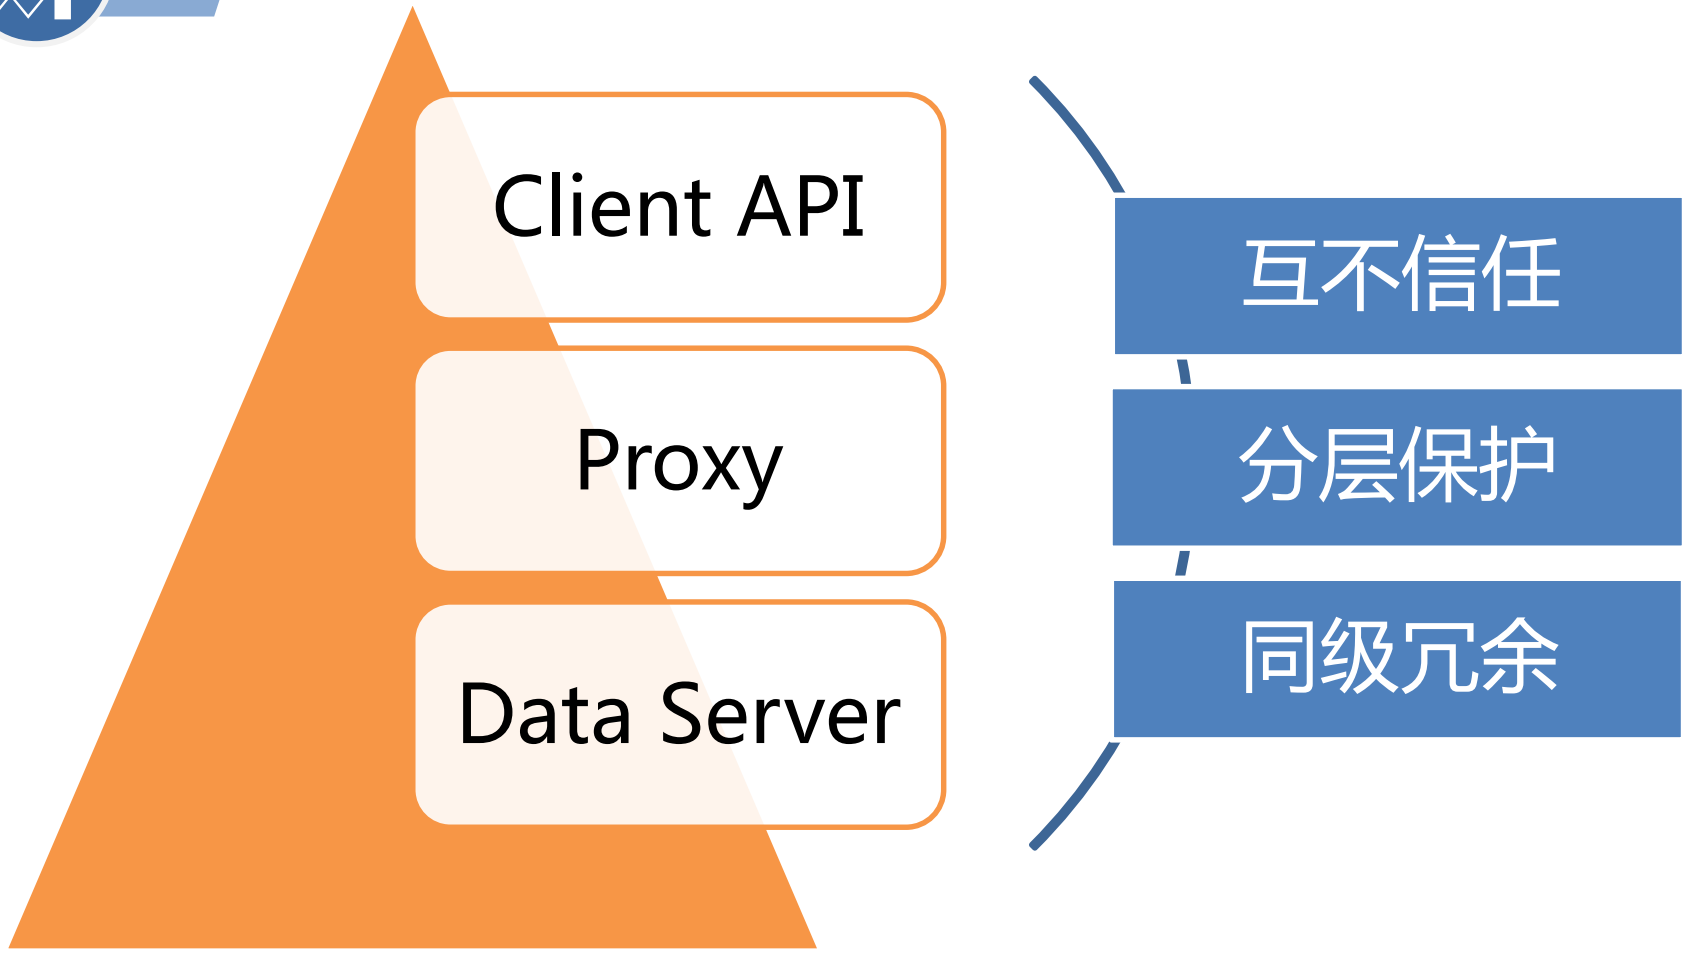

- 电源故障造成某集群1/4的机器掉电（单个机柜）
- 秒级自动恢复，业务几乎无影响

异常检测

自动摘除

跨机柜部署

5. 监控告警

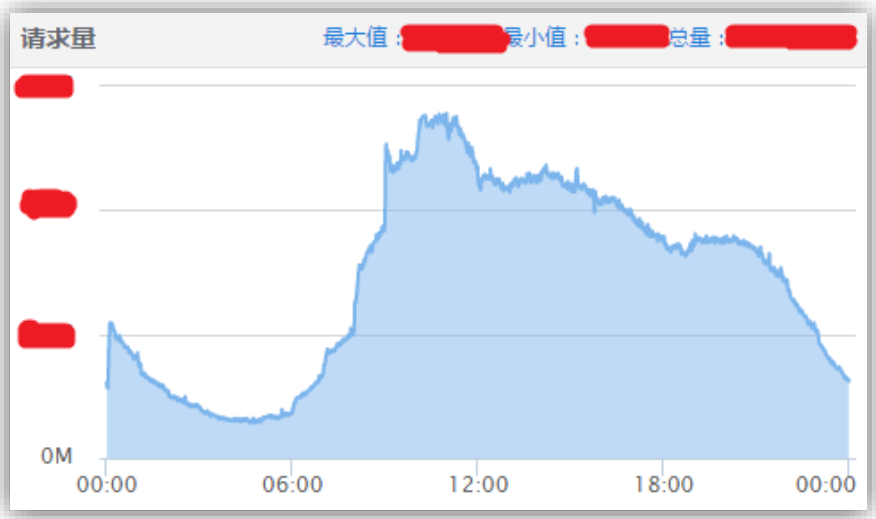

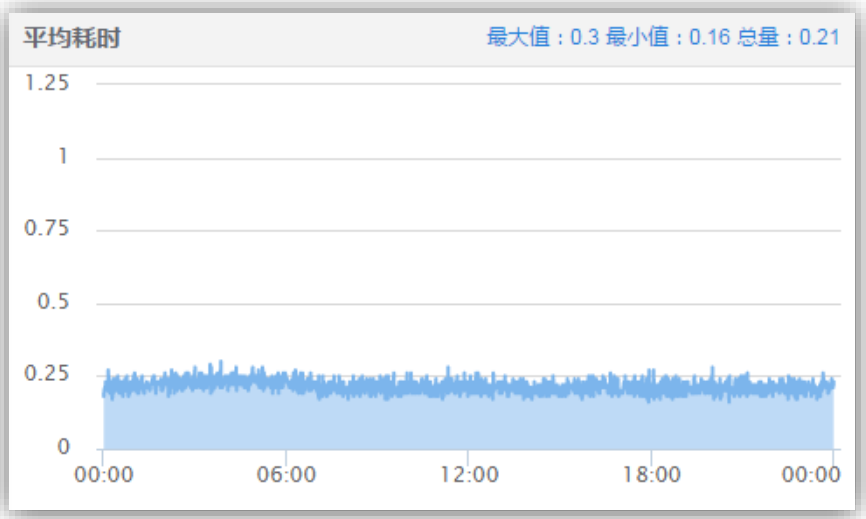

基于日志 ≠ UDP+Agent

开销极小

WTable关键技术

1. 整体架构

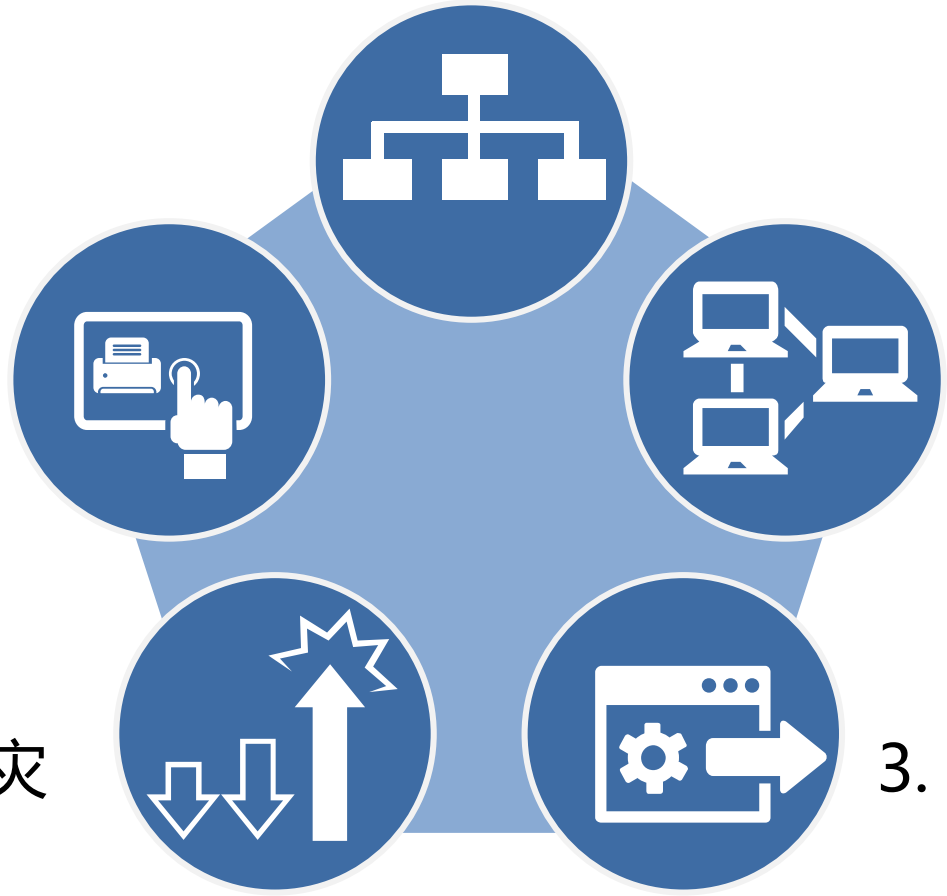

2. 主从同步

3. 横向扩容

4. 容灾

5. 监控告警

典型案例：核心帖子服务

让 生 活 更 简 单

- 58核心帖子服务，百亿个帖子，每天百亿次调用
- id → {帖子信息}

扩容 可用性

爆炸式增长

诚意出售 不限购 精装修 龙湖唐宁one 南向开 2年

五道口 - 唐宁ONE二手房

近地铁 不限购 土巴兔礼包

经纪人：卫峰 今天

350 万 67829元/㎡

1室1厅1卫 (51.6㎡)

地质大学 东西通透2居 无税随时看房 1年

五道口 - 地质大院二手房

有钥即看 土巴兔礼包

经纪人：丁春玲 我爱我家 今天

524 万 80776元/㎡

2室1厅1卫 (64.87㎡)

典型案例：核心帖子服务

- WTable存储设计

	colKey=1	colKey=2
rowKey=id	{userId, 时间, 状态, 类别, ...}	{内容}

- 迁移效果

还有哪些痛点

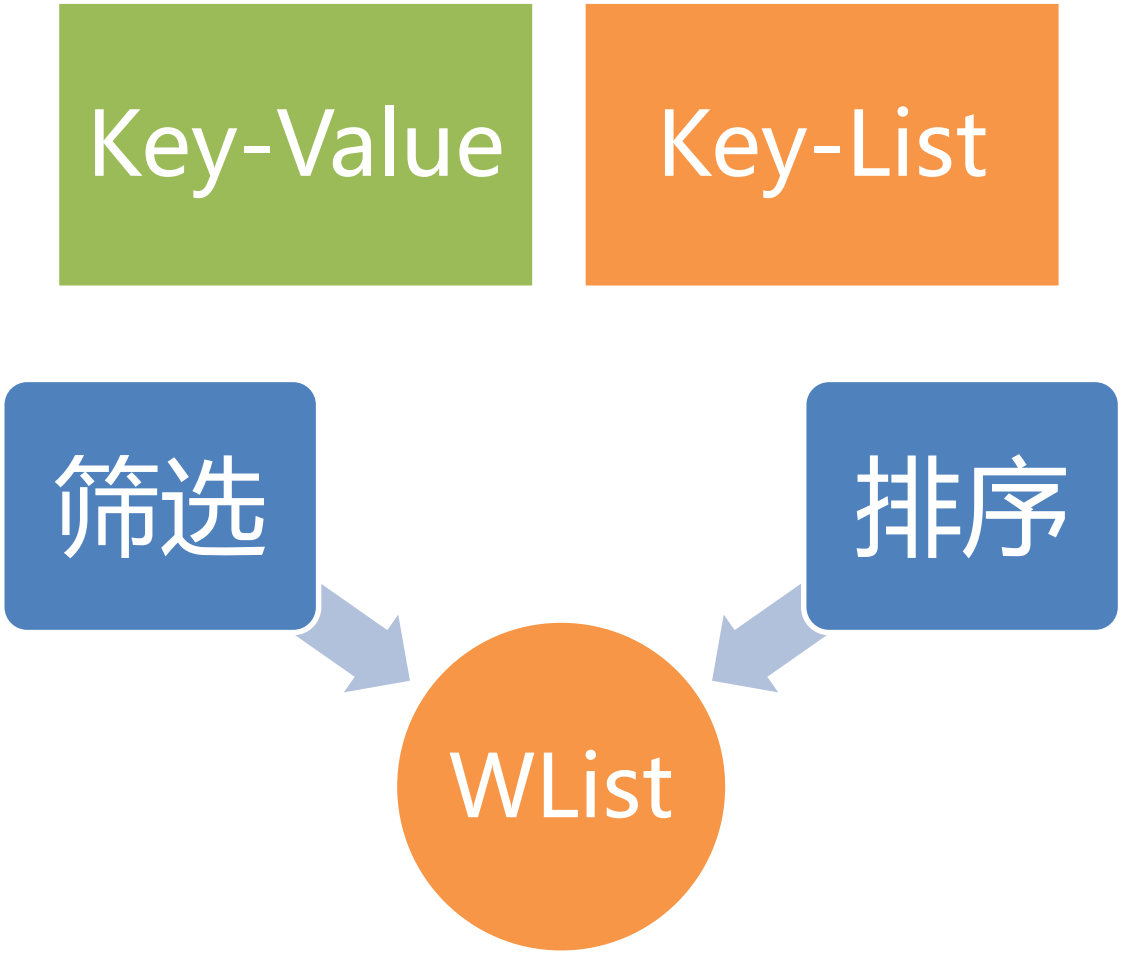

WList列表存储平台

让 生 活 更 简 单

分布式 + Key-List + 筛选 + 排序

- 类SQL语法
  - where category=8&date=14567616_14594400
  - orderby date desc
- 应用场景举例
  - 用户发帖&收藏列表
  - 简历投递&下载记录
  - 好友列表

WList关键技术

- 基于WTable架构设计
- Schema
  - 字段类型int, float, string
  - 字段可随意扩展
- Schema如何设计才能做到效率高？
  - etcd存储schema配置
- 如何在list很长的情况下快速响应？
  - 预排序
  - 缓存
  - 截断

总结

WTable

WList

千亿级

架构

关键技术

案例

Thanks!

让 生 活 更 简 单