



# 微博架构与平台安全

演讲者 @TimYang



# 微博架构发展

- 新浪微博从 0 ~ 50,000,000 用户
- 技术架构经历了 3 个阶段

# 第 I 版

微博

关系

用户

PHP

MySQL

Apache

LINUX

# 技术特点

- 微博本质是解决发表/订阅问题
- 第 1 版采用推消息模式，将发表/订阅简化成 insert / select 问题

# 技术细节

- 典型 LAMP 架构
- MySQL：单库单表, MyISAM
- MPSS (Multi-Port Single Server)

Service1

Service2

Service3

Service1 Service2 Service3

Service1 Service2 Service3

Service1 Service2 Service3

# 快速成长

- 用户快速增长
- 出现发表延迟现象，尤其是明星用户

# 架构演变

- 分发推送是造成发表延迟首因
  - 模式改进
- 数据规模增大也带来一定延迟
  - 规模增大：数据拆分
  - 锁表问题：更改引擎
  - 发表过慢：异步方式

# 第 2 版

应用层

微博  
(推改进)

关系

用户

计数

短链

服务层

DB  
(拆分)

Cache

存储

实时搜索

MQ  
(异步发表)

基础层

# 投递模式优化

- 推模式改进，不需要推送到所有用户
- 存储及发表峰值压力减轻
- 投递延迟减小

# 数据拆分

- 优先按时间维度拆分
- 内容和索引分开存放
- 内容使用 key-value 方式存储 (NoSQL)
- 索引由于分页访问，拆分有挑战

# 异步处理

- 发表异步化
- 发表速度及可靠性得到提高
- 使用 MemcacheQ
- 增加 stats queue，适合大规模运维

# 技术细节

- InnoDB 引进，避免锁表烦恼
- PHP 中 libmemcached 替换 memcache
- 在高并发下稳定性极大提高

# 高速发展

- 系统问题
  - 单点故障、“雪崩”
  - 访问速度，国内复杂网络环境
- 数据压力及峰值
  - MySQL 复制延迟、慢查询
  - 热门事件微博发表量，明星评论及粉丝

# 如何改进

- 系统方面
  - 允许任意模块失败
  - 静态内容 CDN 加速
- 数据压力及峰值
  - 将数据、功能、部署尽可能拆分
  - 提前容量规划

# 平台化需求

- Web 系统
  - 有用户行为才有请求
- API 系统
  - 轮询请求
  - 峰值不明显
  - 用户行为很难预测

- 系统规模持续增大
- 平台化需求
- 新的架构如何设计？

- “Break large complex systems down into many services... google.com search touches 100s of services (ads, web search, books, news, spelling correction...)”
- - Jeff Dean, Google Fellow

# 服务化

- 服务 → 接口 → 应用

# 第 3 版

API

微博  
(新引擎)

关系  
(多索引)

用户

计数  
(基于偏移)

图片池

平台服务

应用服务

DB  
(多维度)

Cache  
(分层)

存储  
(去中心)

MQ  
(自动化)

实时搜索

IDC 同步

基础服务

# 平台服务

- 平台服务和应用服务分开，模块隔离
- 新微博引擎，实现 feed cache 分层
- 关系多维度索引结构，性能极大提高
- 计数服务改成基于偏移，更高的一致性、低延迟

# 基础服务

- DB 冷热分离等多维度拆分
- 图片等存储去中心化
- 动态内容支持多 IDC 同时更新



# 高性能架构

- 50,000,000 用户使用新浪微博
- 最高发表 3,000 条微博 / 秒
- 姚晨发表一条微博，会被 3,689,713 粉丝读到（11月10日数据）

# 问题本质

- 解决高访问量、海量数据规模下
- 易于扩展、低延迟
- 高可用

异地分布能力

- 每天数十亿次Web及接口请求
- 请求内容随时变化，结果无法 cache
- 如何扩展？

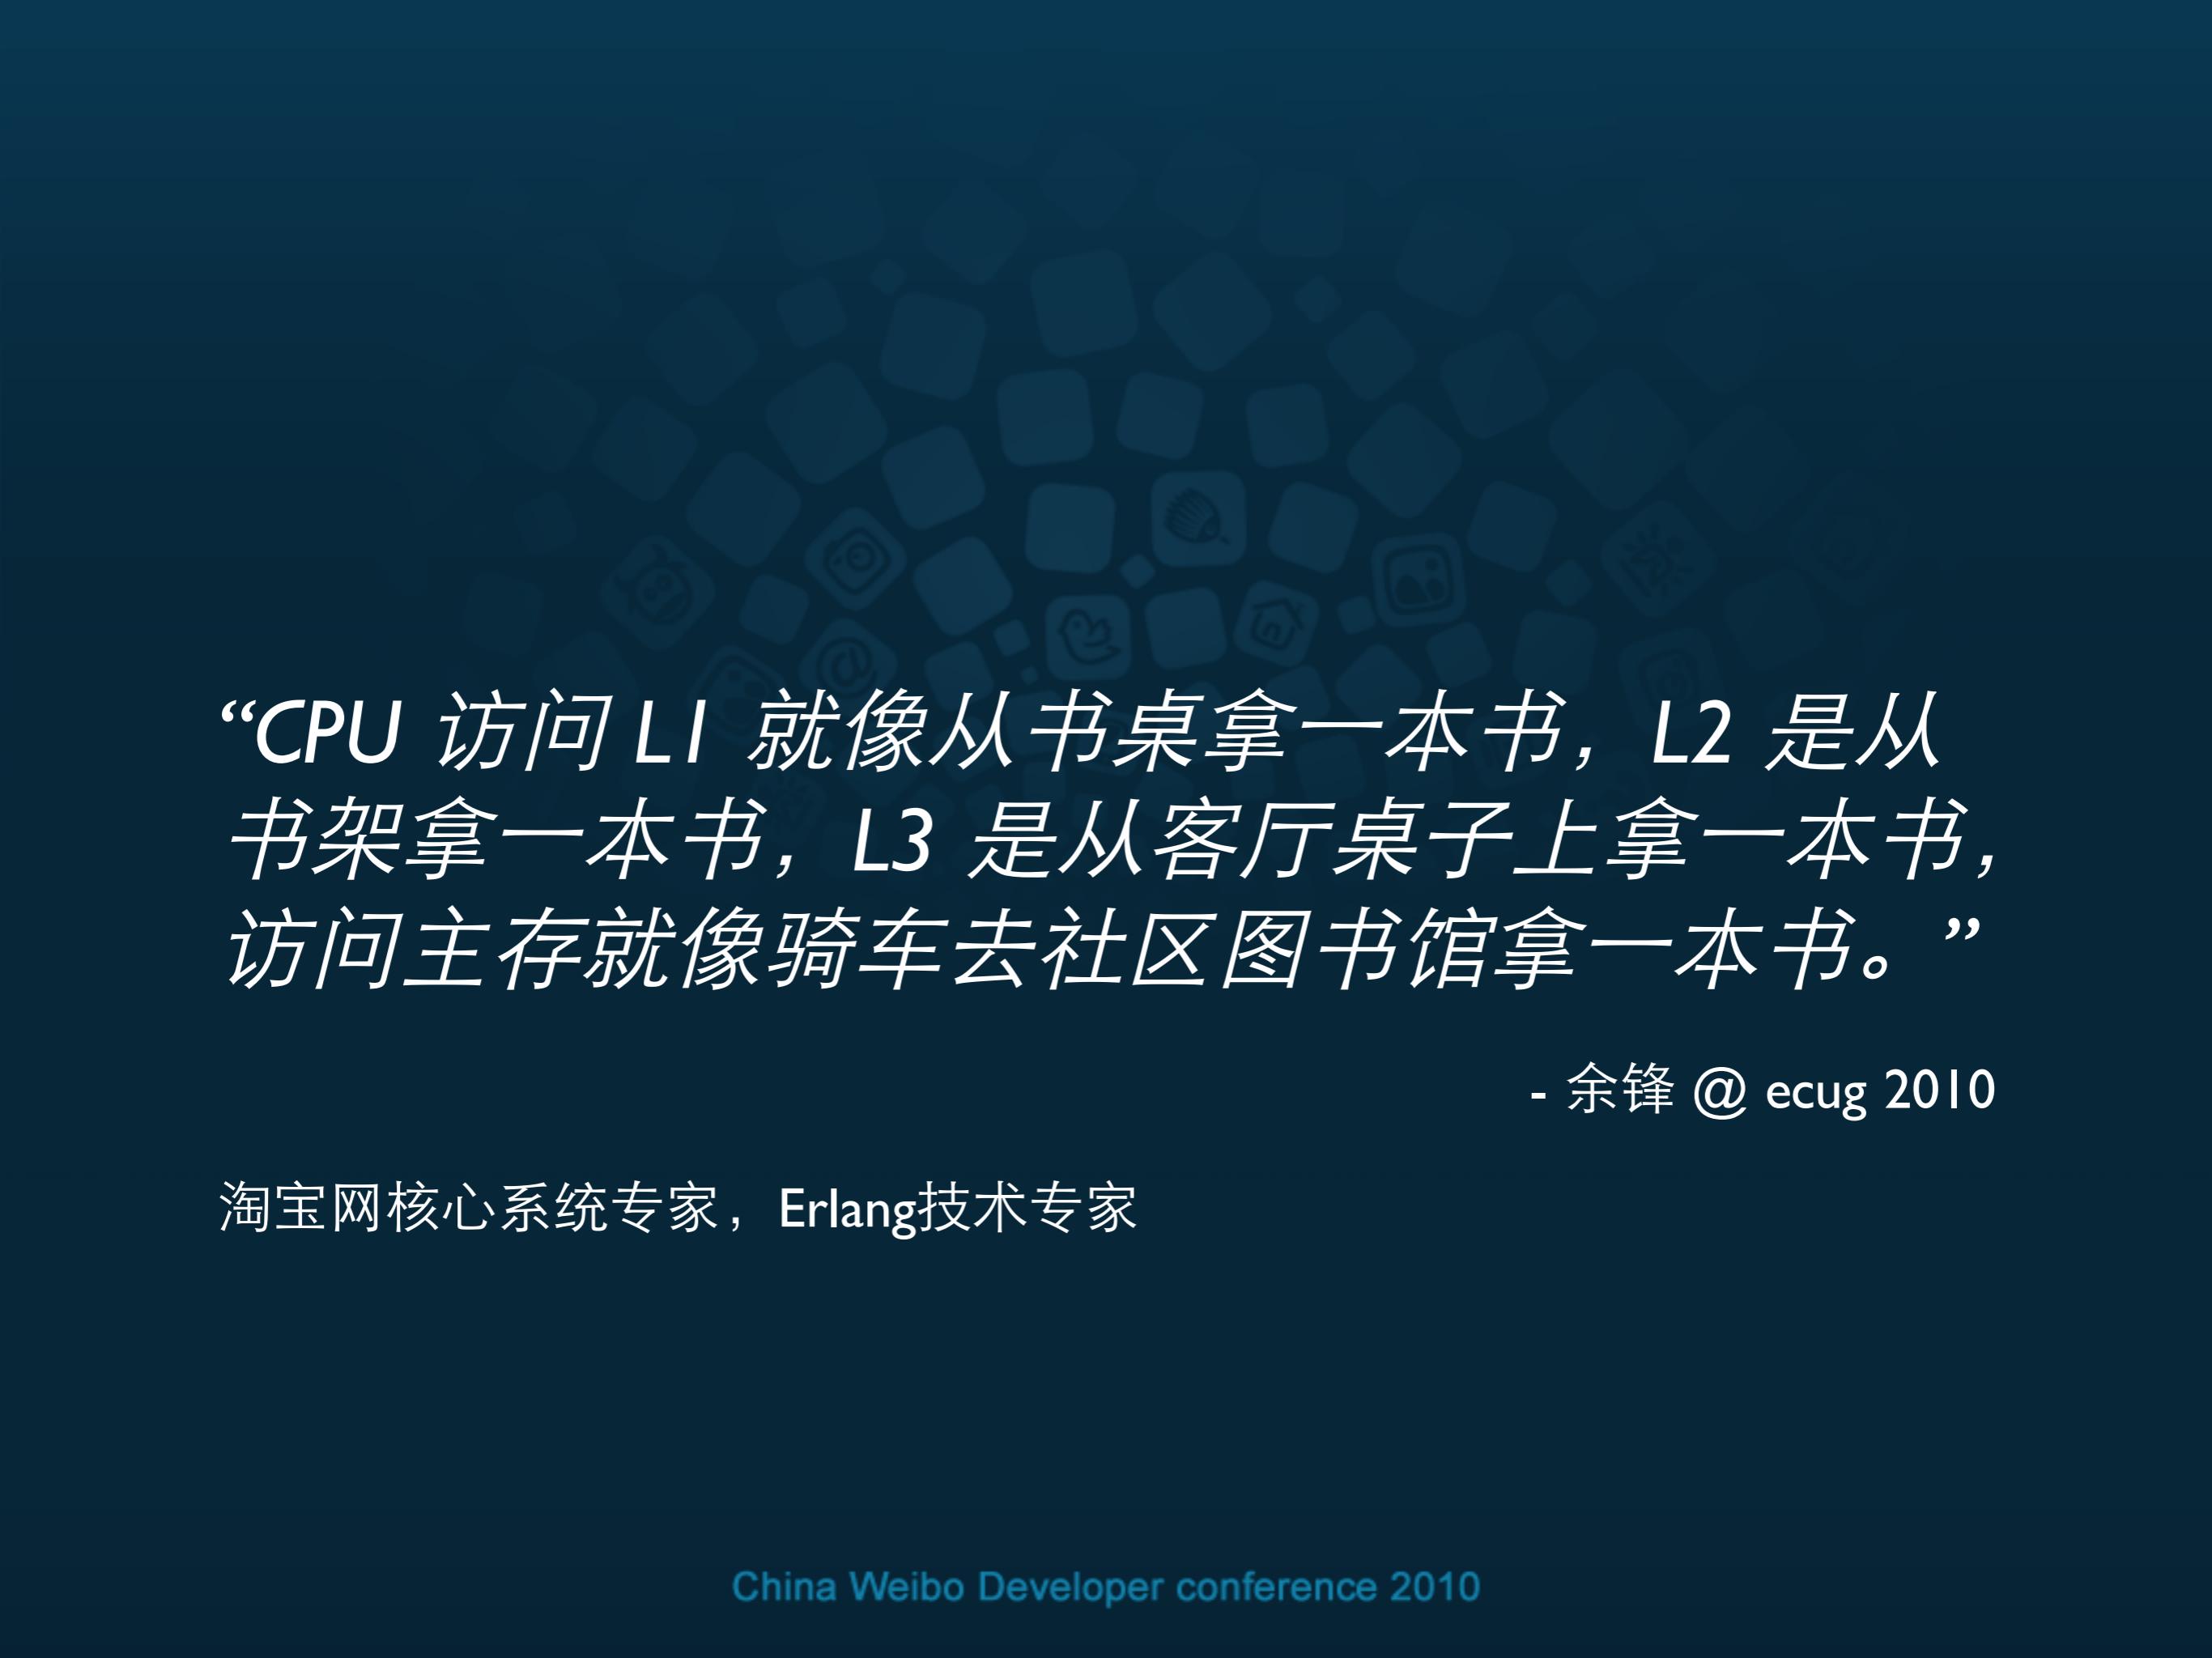
# 思路

- 去状态，可请求服务单元中任意节点
- 去中心化，避免单点及瓶颈
- 可线性扩展，如
  - 100 万用户，10 台服务器
  - 1000 万用户，100 台服务器
- 减少模块耦合

# 实时性

高性能系统具备低延迟、高实时性

实时性核心是让数据离 CPU 最近，避免磁盘 IO



“CPU 访问 L1 就像从书桌拿一本书，L2 是从书架拿一本书，L3 是从客厅桌子上拿一本书，访问主存就像骑车去社区图书馆拿一本书。”

- 余锋 @ ecug 2010

淘宝网核心系统专家，Erlang技术专家

# 微博 cache 设计

**INBOX  
(HOME)**

L0 cache

**OUTBOX  
(MYFEED)**

L1 cache  
(最近发表)

L2 cache  
(中期)

**CONTENT**

L0 cache  
(热门内容)

L1 cache  
(最近发表)

L2 cache  
(中期)

# 高可用

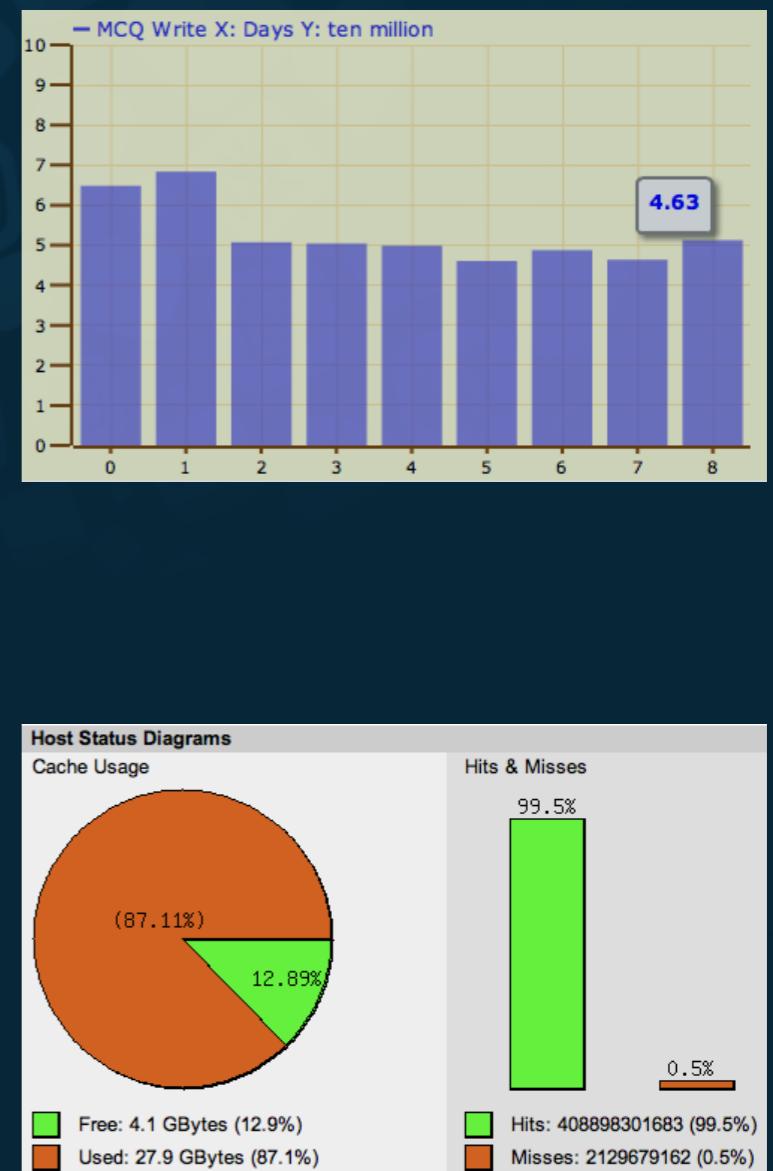
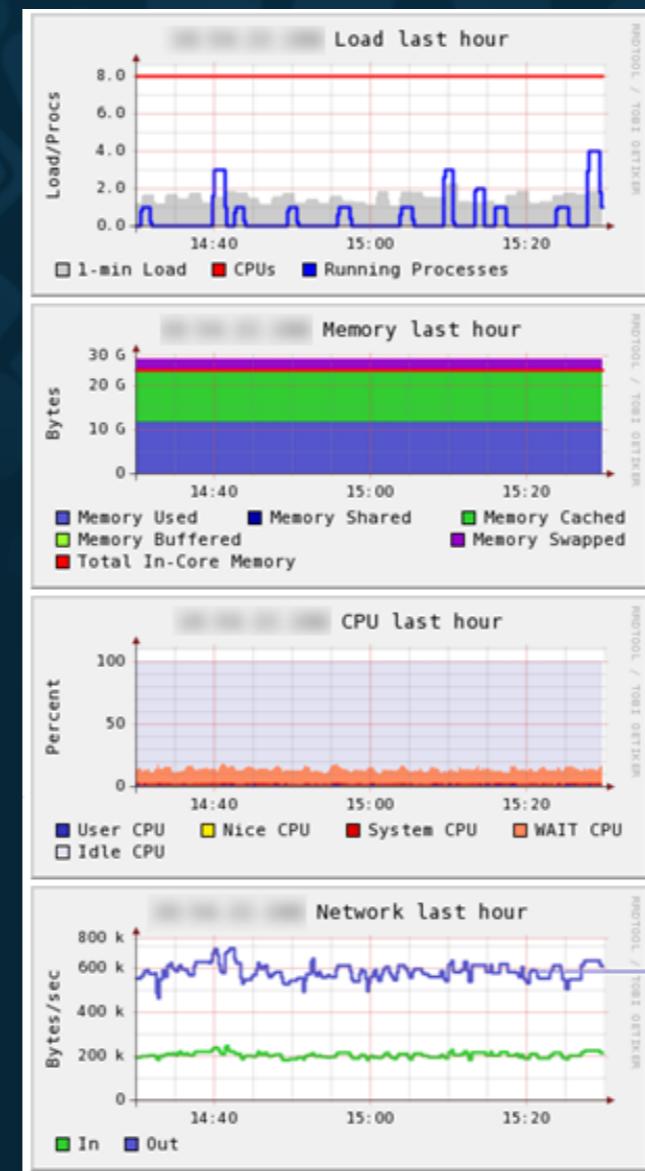
- 好的架构具有高可用性
- 业界
  - Amazon S3: 99.9%
  - Amazon EC2: 99.95%
  - Facebook: n/a
- 微博平台 ~ 99.95% (5 小时 / 年)

# 如何达到

- 容量规划
  - 图表
- 监控及 admission control...
  - 接口及资源监控, 7x24
  - 业务回环测试, 监测业务逻辑有效性
  - 集成测试

# 图表

通过图表  
了解系统容量



# 接口监控

- curl / 各地请求情况及响应时间
- 流量异常 / access log
- non-200 结果 / 失败率 / exceptions
- 将监控指标量化
  - 类似 mysql seconds behind master

- “*Many services are written to alert operations on failure and to depend upon human intervention for recovery, about 20% of the time they will make mistakes.*
- *Designing for automation.”*
  - - James Hamilton, VP of Amazon

# 自动化

- 大规模互联网系统运作需要尽可能自动化
- 发布及安装
- 服务启用、停止
- 故障处理
- 前提，去状态化，允许单点故障及重启

- “*System administration at Google usually have 1 week of "on call" duty, and the other 5 weeks are spent making improvements to make the on call portion more optimized, automated, and trouble-free*”
  - - Tom Limoncelli @ Everything Sysadmin
  - Lumeta Corporation总监, 贝尔实验室专家

# 微博系统运转依赖大量自动化工具

## 工具在持续改进并增加中.....

```
Master_Auto_Failover(...)  
If MasterActive() = Failed  
    Get_All_Slave_Servers()  
For (;;) {  
    Change_Master_To()  
    Modify_DNS_Resolve()  
  
    Rebuild_Slave(...)  
    If This_Slave_Backup_exist = True  
        rsync data from backup  
    Start_Slave();  
    If Slave_OK = True  
        add_DNS_Resolve();  
    }  
}
```

- 高可用性还有异地分布的需求
- 在国内网络环境下，IDC 灾难、机房检修维护会导致服务中断
- 用户就近访问可提高速度

- 静态内容分布采用 CDN 技术，成熟
- 动态内容分布是业界难点
- 核心是数据的分布式存储

- 理想的分布式存储产品
  - 支持海量规模、可扩展、高性能、低延迟、高可用性
  - 多机房分布，异地容灾
  - 调用简单，具备丰富数据库特性



分布式存储

需要解决多对多的数据复制同步

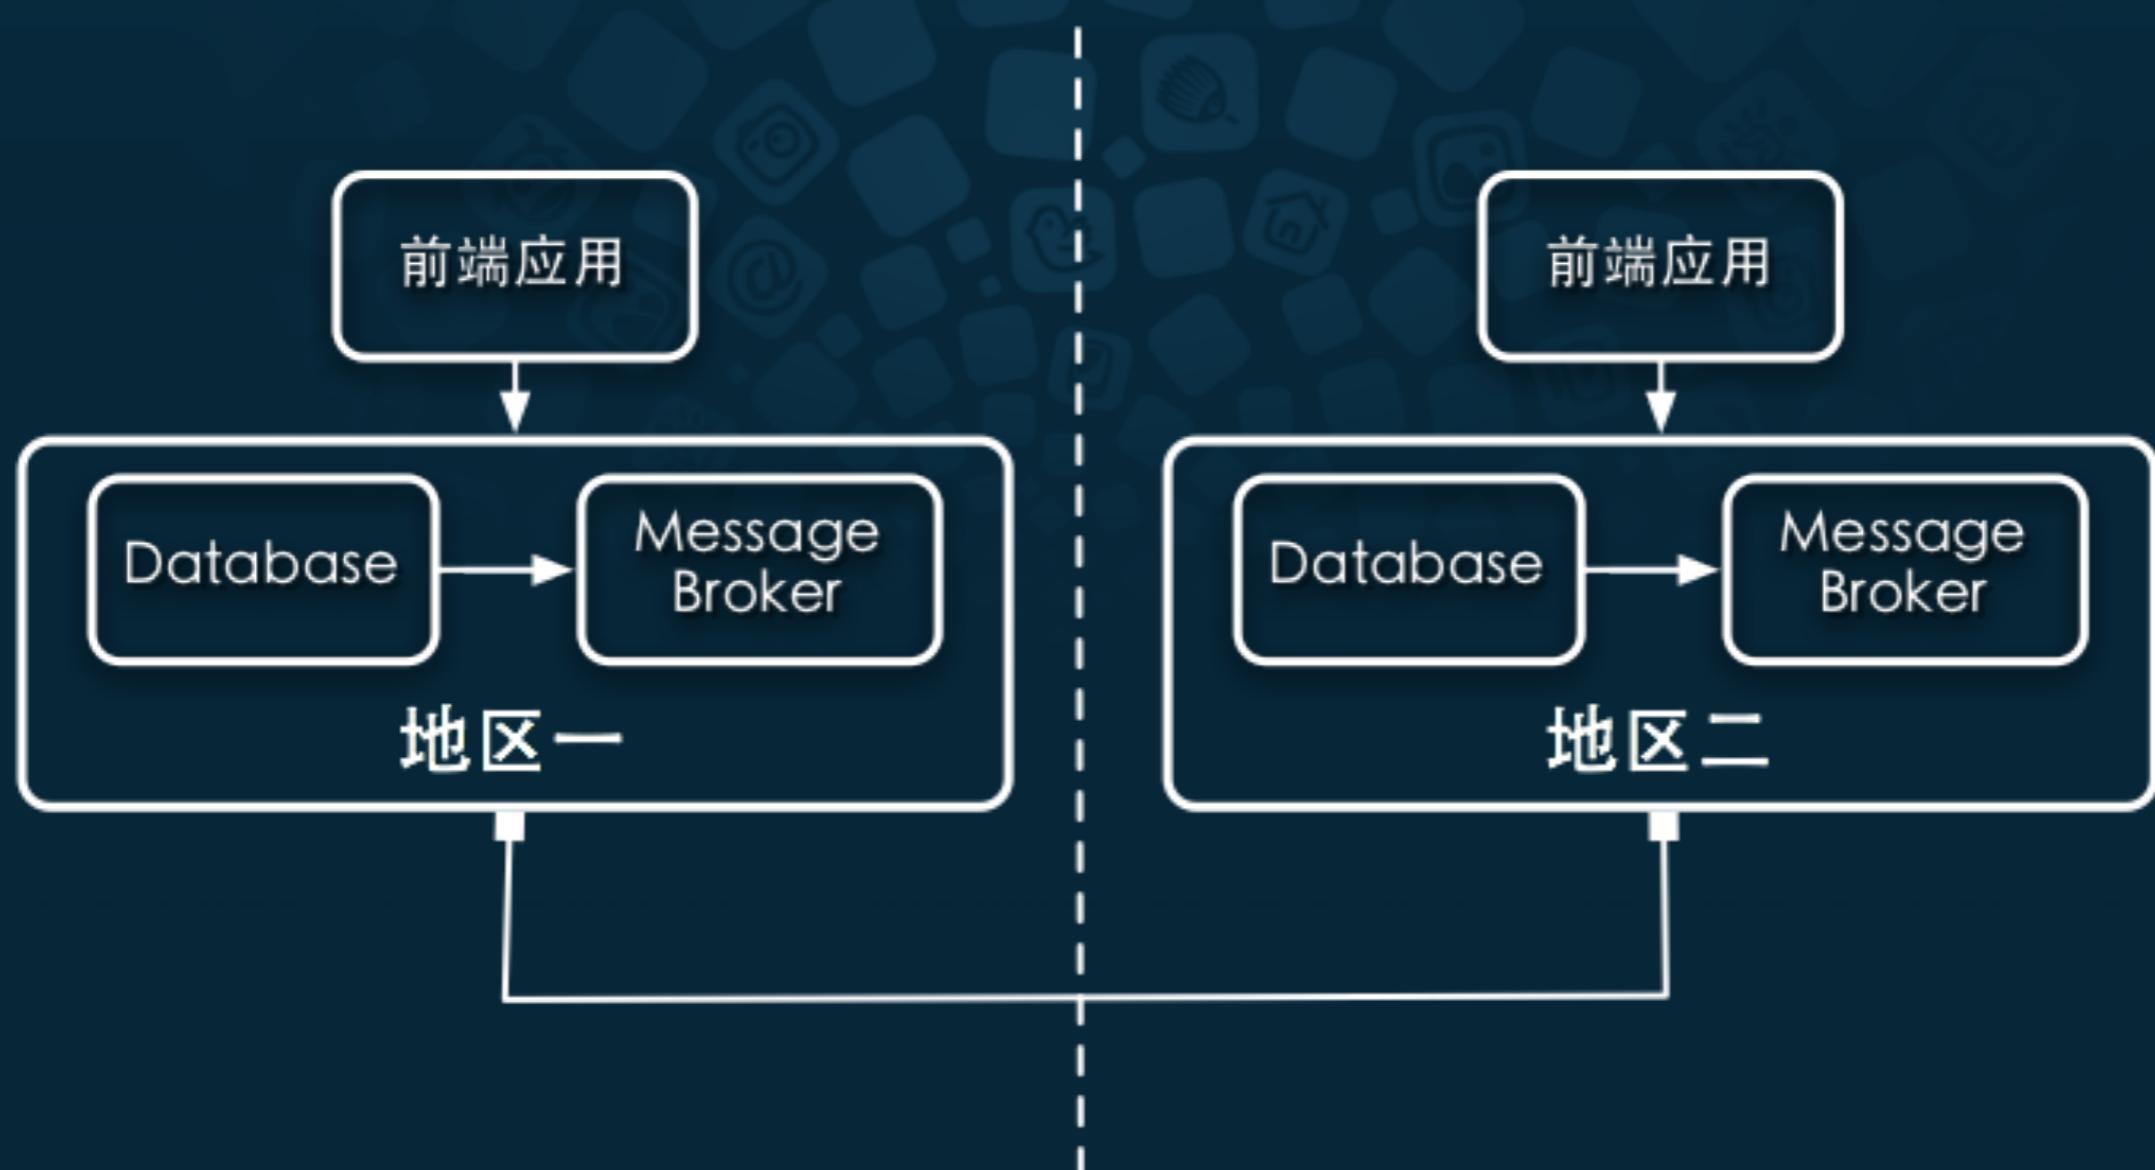
及数据一致性

# 复制策略

- Master / Slave
  - 实现简单，master 有单点风险
- Multi-Master
  - 合并多处写，异步，最终一致性
  - 需要应用避免冲突
- Paxos：强一致性，延迟大

- Multi-Master
- Web 应用多地区同步的最佳策略
- 没有现成熟的产品

# 微博方案



- 通过消息广播方式将数据多地分布
- 类似 Yahoo! Message Broker

- “We use YMB for replication for 2 reasons.
- 1.YMB ensure msgs are *not lost before they are applied to the db*.
- 2.YMB is *designed for wide-area replication. This isolates individual PNUTS clusters from dealing with update between regions*”
  - PNUTS:Yahoo!’s Hosted Data Serving Platform



# 新推送架构

# 现状

- API 大部分请求都是为了获取最新数据
- 重新思考 Rest API
  - 大部分调用都是空返回
  - 大部分时间在处理不必要的询问
  - 无法实时投递
  - 存在请求数限制 (rate limit)

# 如何解决

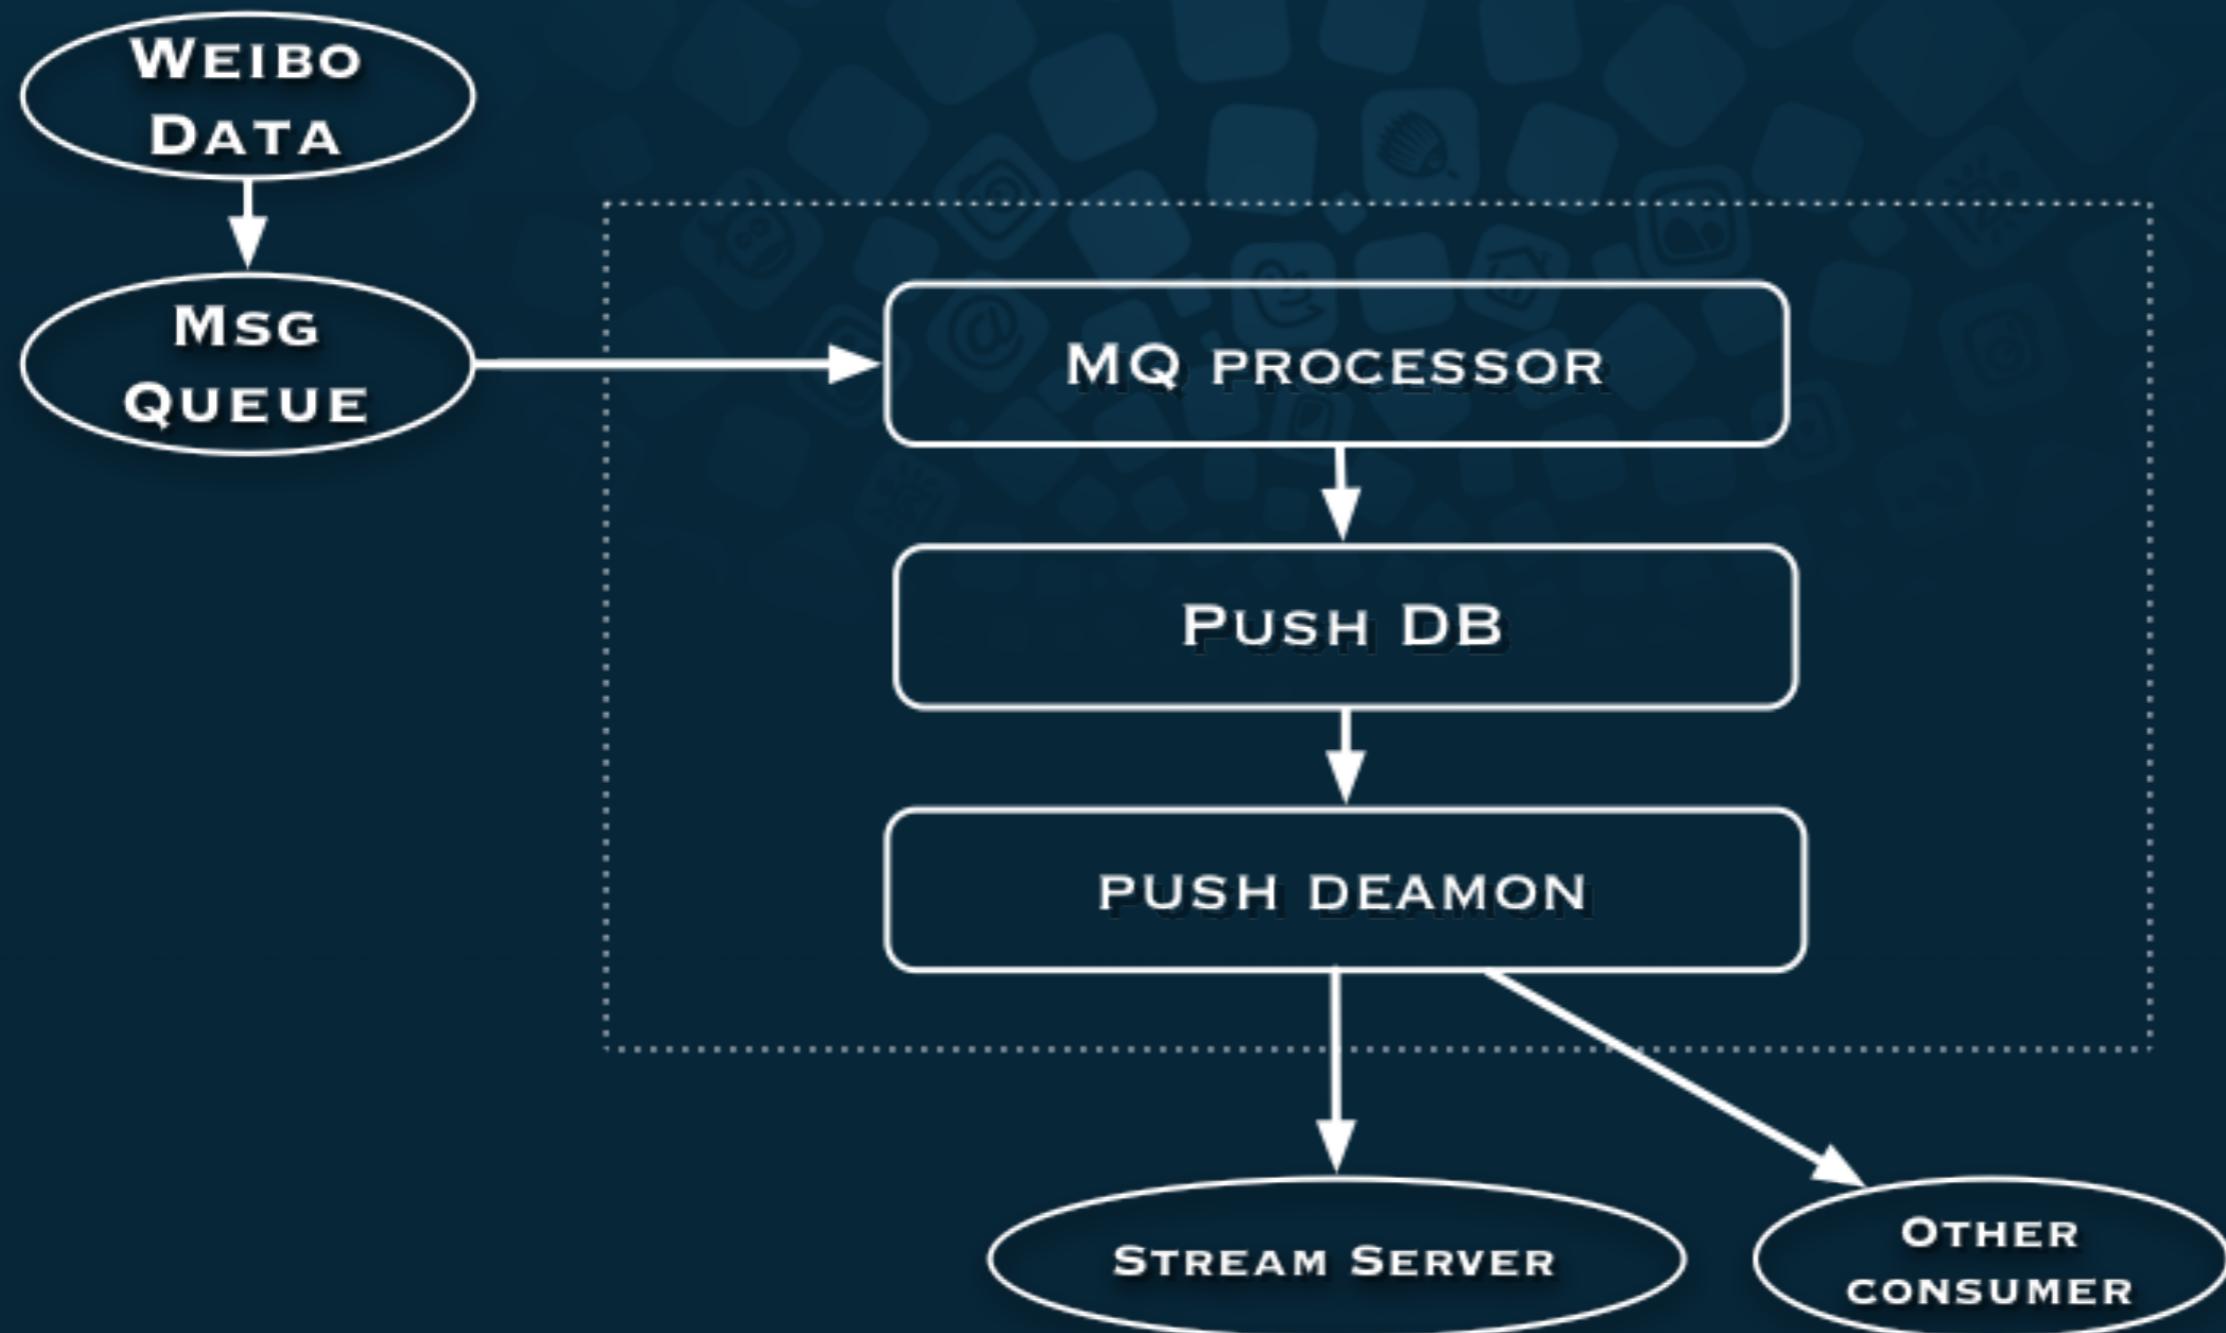
- 新一代推送接口(Stream API)
- 采用推送的方式
  - 有新数据服务器立即推送给调用方
  - 无数据则不消耗流量
  - 客户端实现更简单

```
$ curl -u 10503:xxx http://api.t.sina.com.cn/\-  
stream?uid=10503&since_id=221101112665265772  
  
{"created_at": "Fri Nov 12 18:29:53 +0800 2010",  
 "id": 221101112665265772,  
 "text": "test msg",  
 "source": "null",  
 "favorited": false,  
 "truncated": false,  
 "in_reply_to_status_id": "",  
 "in_reply_to_user_id": "",  
 "in_reply_to_screen_name": "",  
 "geo": null,  
 "user": {"id": 1432494550, "screen_name": "Thomas"}},  
 {"created_at": "Fri Nov 12 18:29:55 +0800 2010",  
 "id": 201101111650165100,  
 "text": "..."},  
 ...
```

# 技术特点

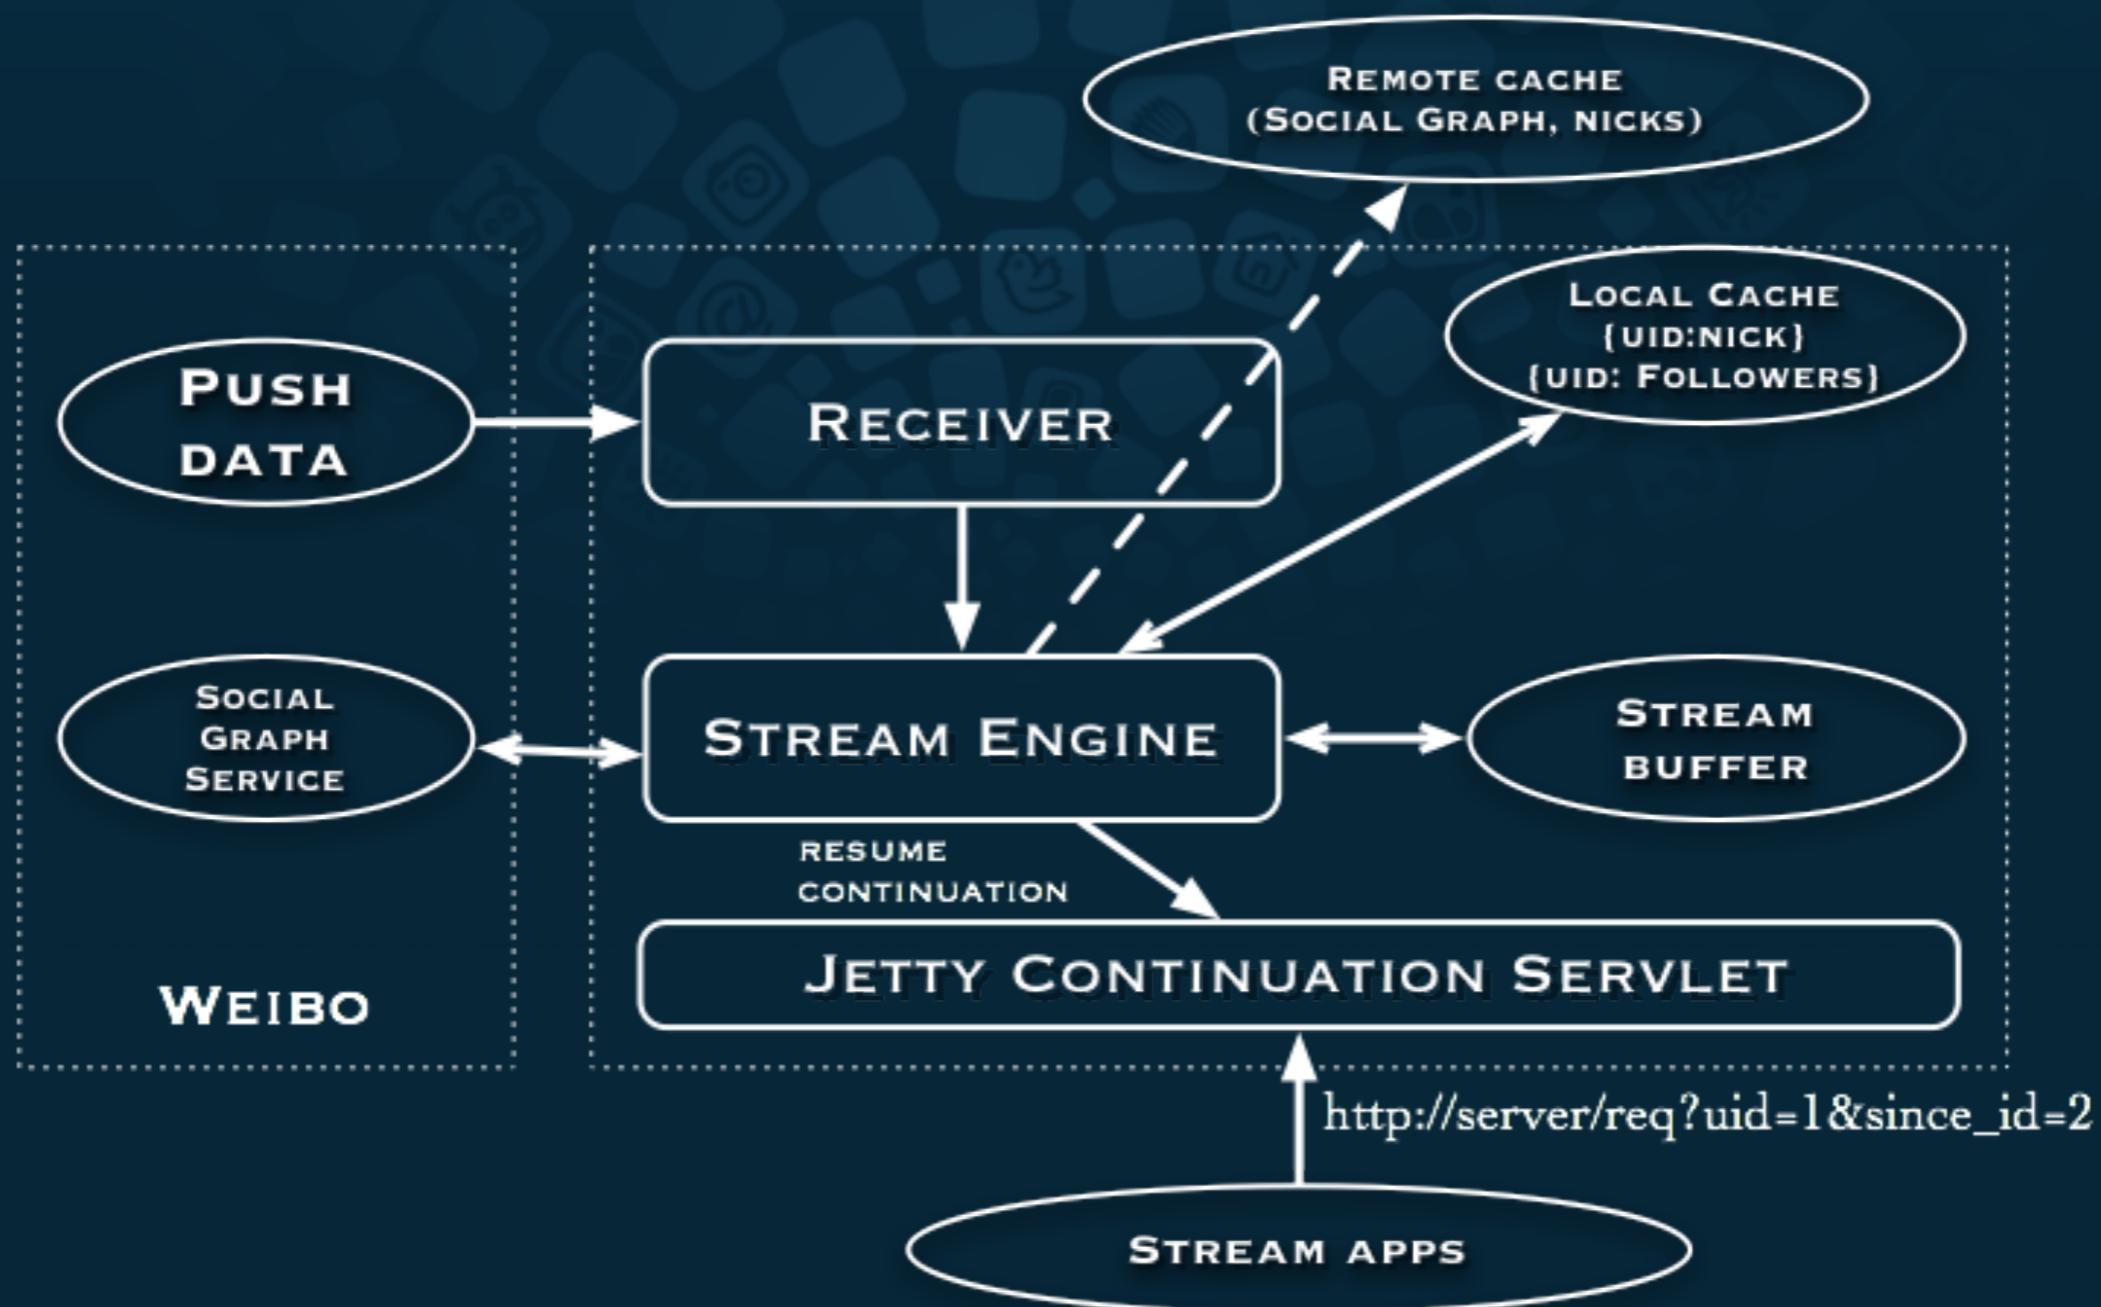
- 低延迟，从发表到客户端接收1秒内完成
- 高并发长连接服务

# 推送架构



- 为什么先持久化
- KISS, Keep It Simple and Stupid
- 测试表明持久几乎不增加延迟开销
  - batch insert
  - cursor read

# 内部细节



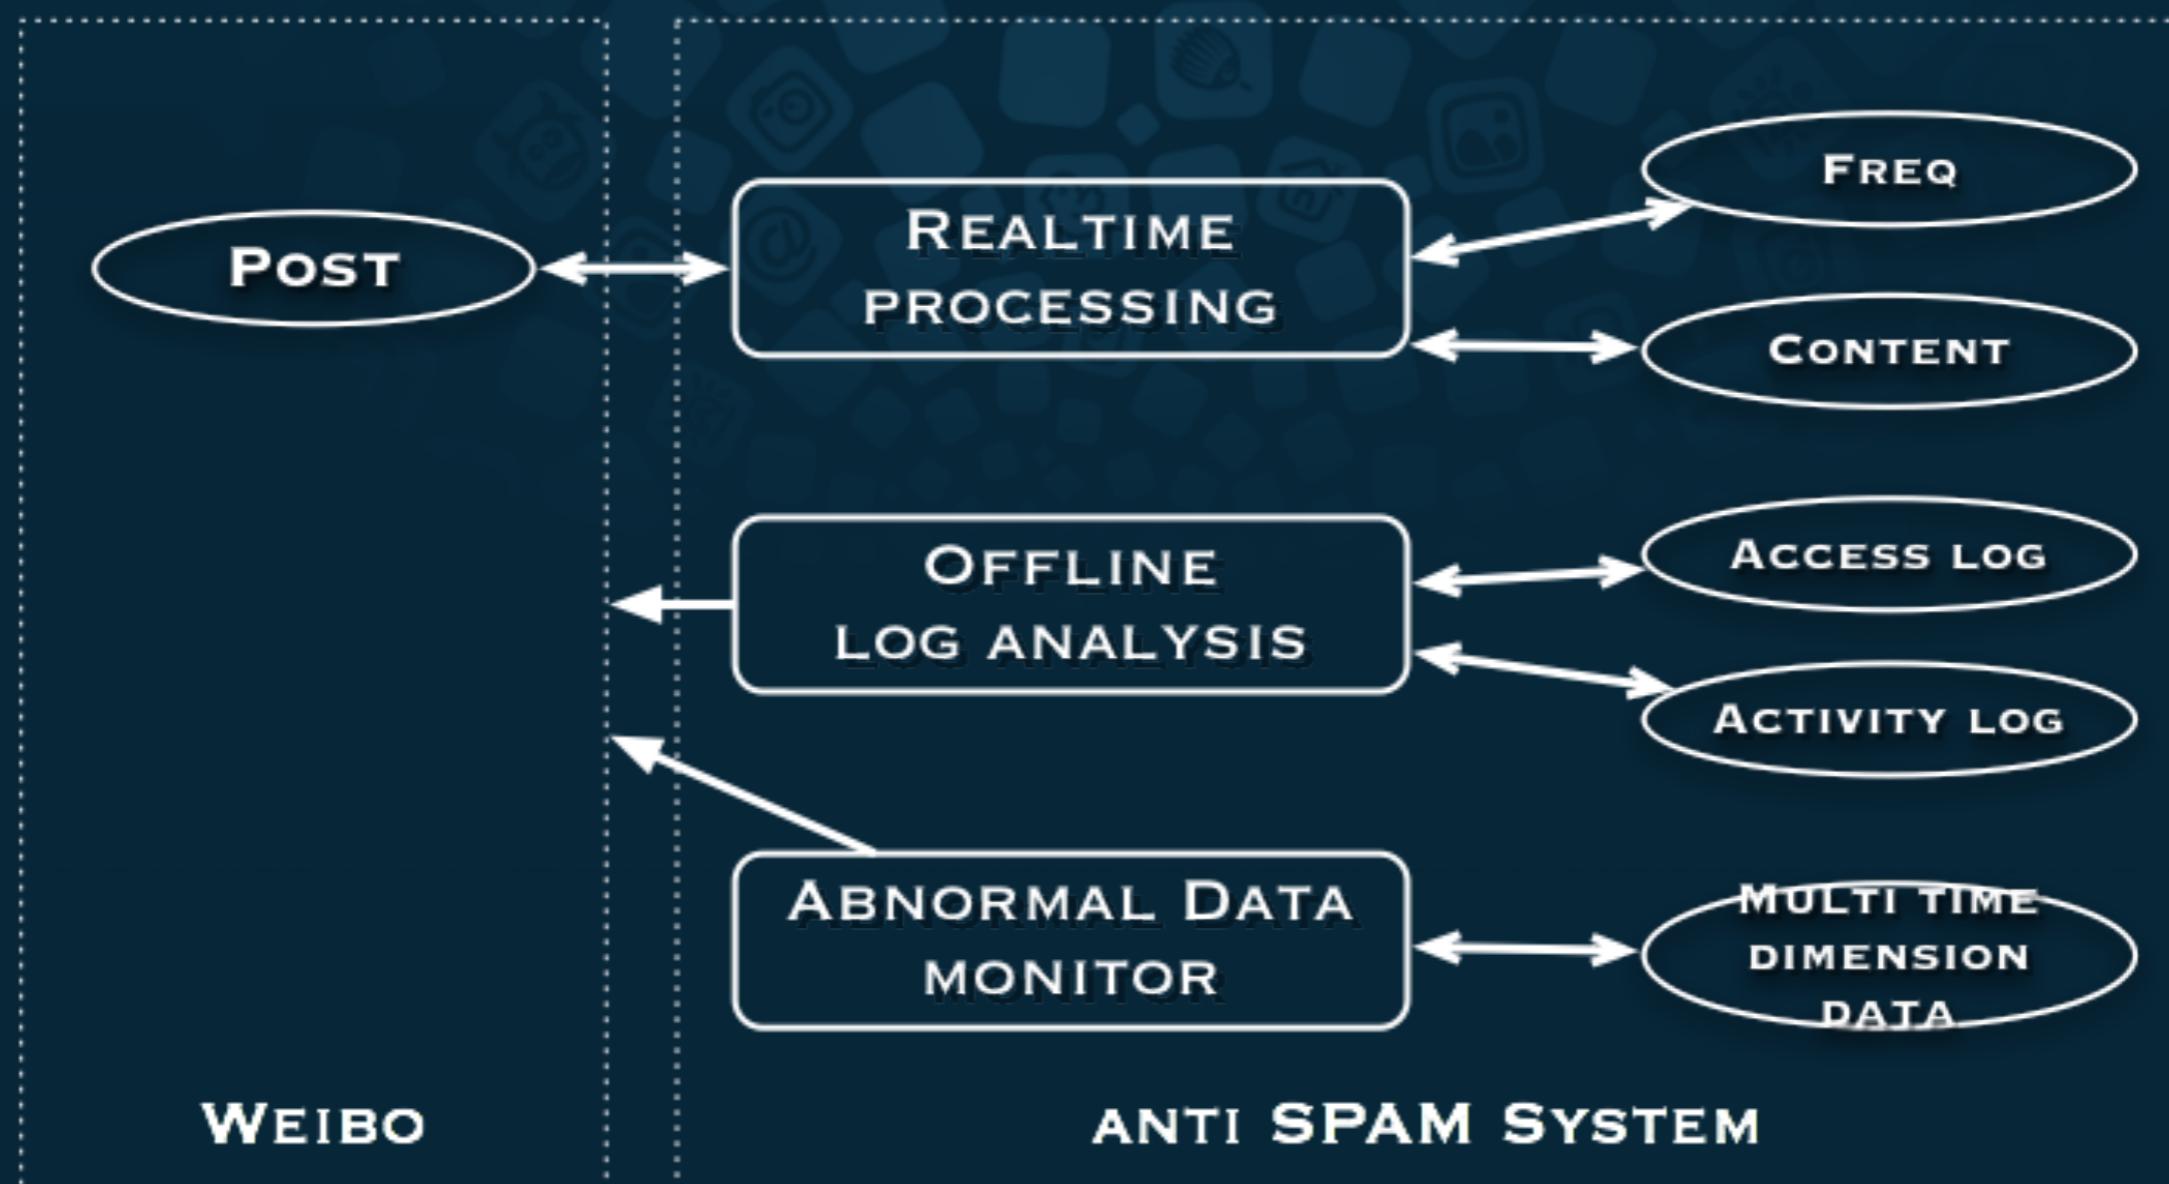
- Stream Buffer
- 保存用户最近数据
- 保存客户端断线重连之间下行数据



# 平台安全

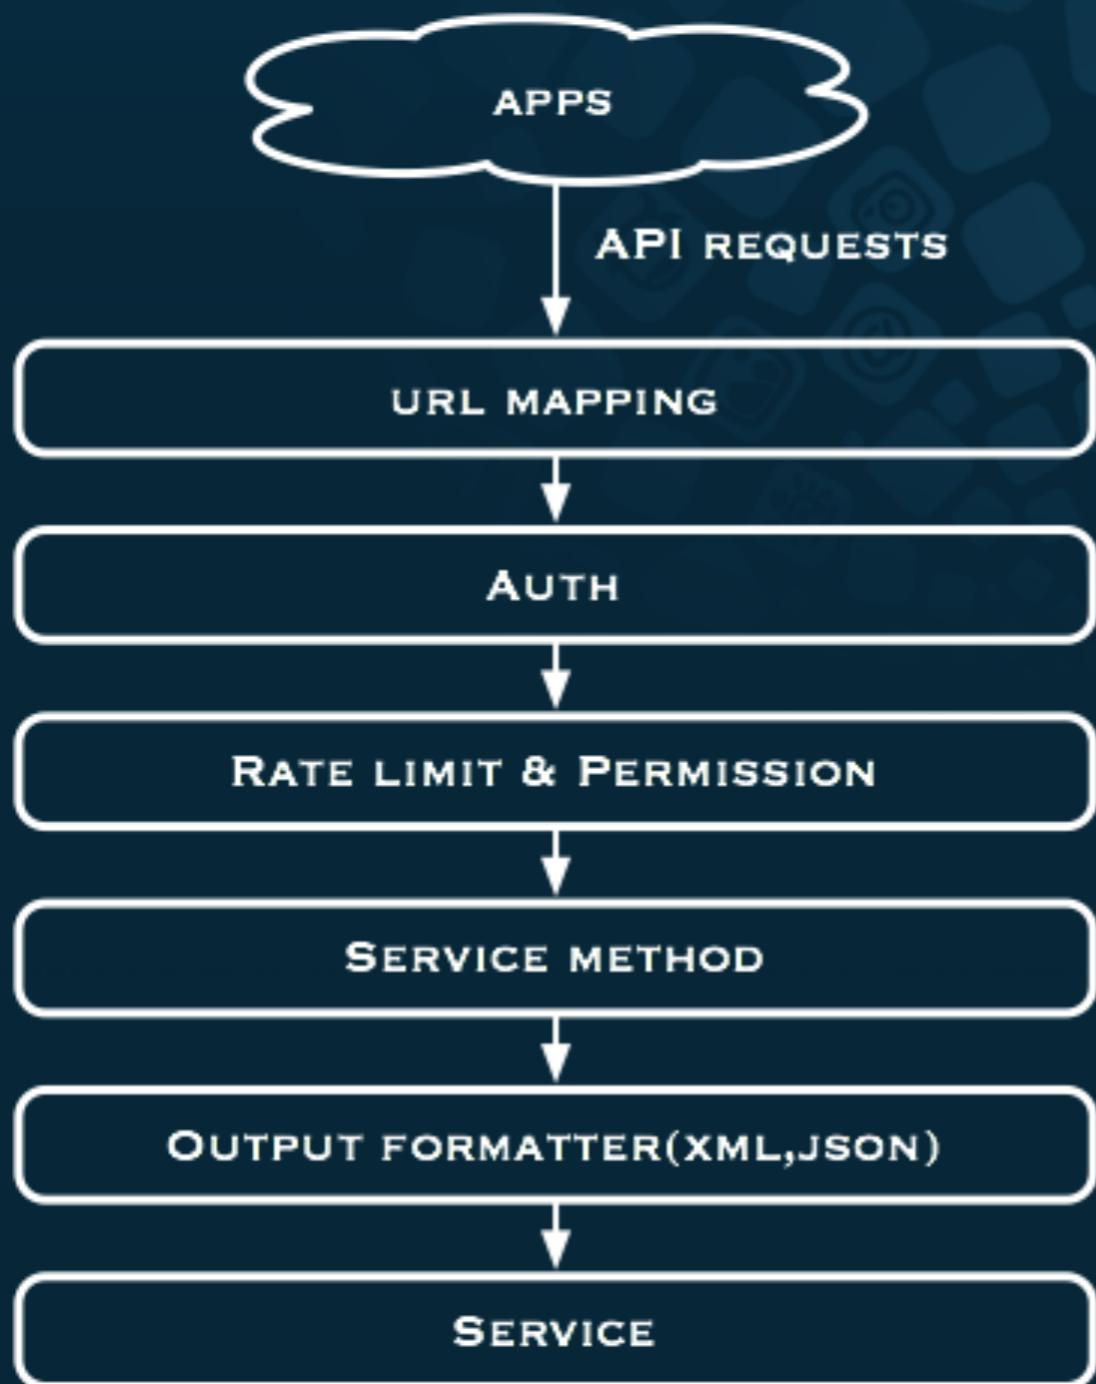
- 由于接口开放，需要防范各种恶意行为
  - 垃圾内容
  - 垃圾粉丝
  - 恶意行为

# 内容安全



- 微博平台需要
- 为用户提供安全及良好体验的应用
- 为开发者营造公平的环境
- 接口需要清晰的权限控制及安全规则

# 接口安全



- Auth层
  - 访问需要 AppKey
  - 需要 OAuth 授权
- 权限层
  - 流量控制、权限

- 架构就是将复杂问题抽象简单并解决

- 下一代微博架构，期待您的参与
- Join us! @TimYang



**THANKS**