

大数据分布式系统并行设计与I/O优化

微博 : @卢亿雷

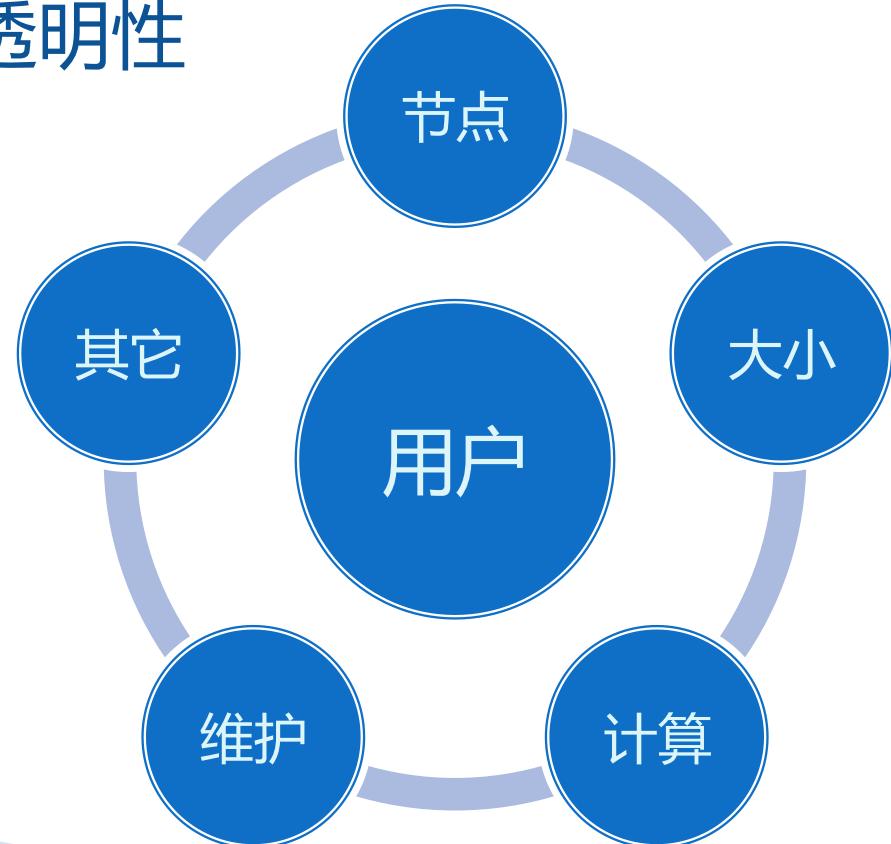
邮箱 : johnlya@163.com

提纲

- ▶ 分布式并行系统定义
- ▶ 分布式并行系统的特点
- ▶ 分布式并行系统生态图
- ▶ 分布式并行系统设计
- ▶ 案例分析
- ▶ 单台机器并行设计
- ▶ 分布式并行I/O优化
- ▶ 单台机器分布式化设想

分布式并行系统定义

- 是多个系统的集合
- 子系统平行地相互作用
- 具有很好的低依赖性和透明性



分布式并行系统的特点

高可靠性

- 数据需要多份存储，保证数据不丢失

高可用性

- 提供7X24小时服务，保证服务不中断

高扩展性

- 提供透明升级扩容服务，保证服务不受限制

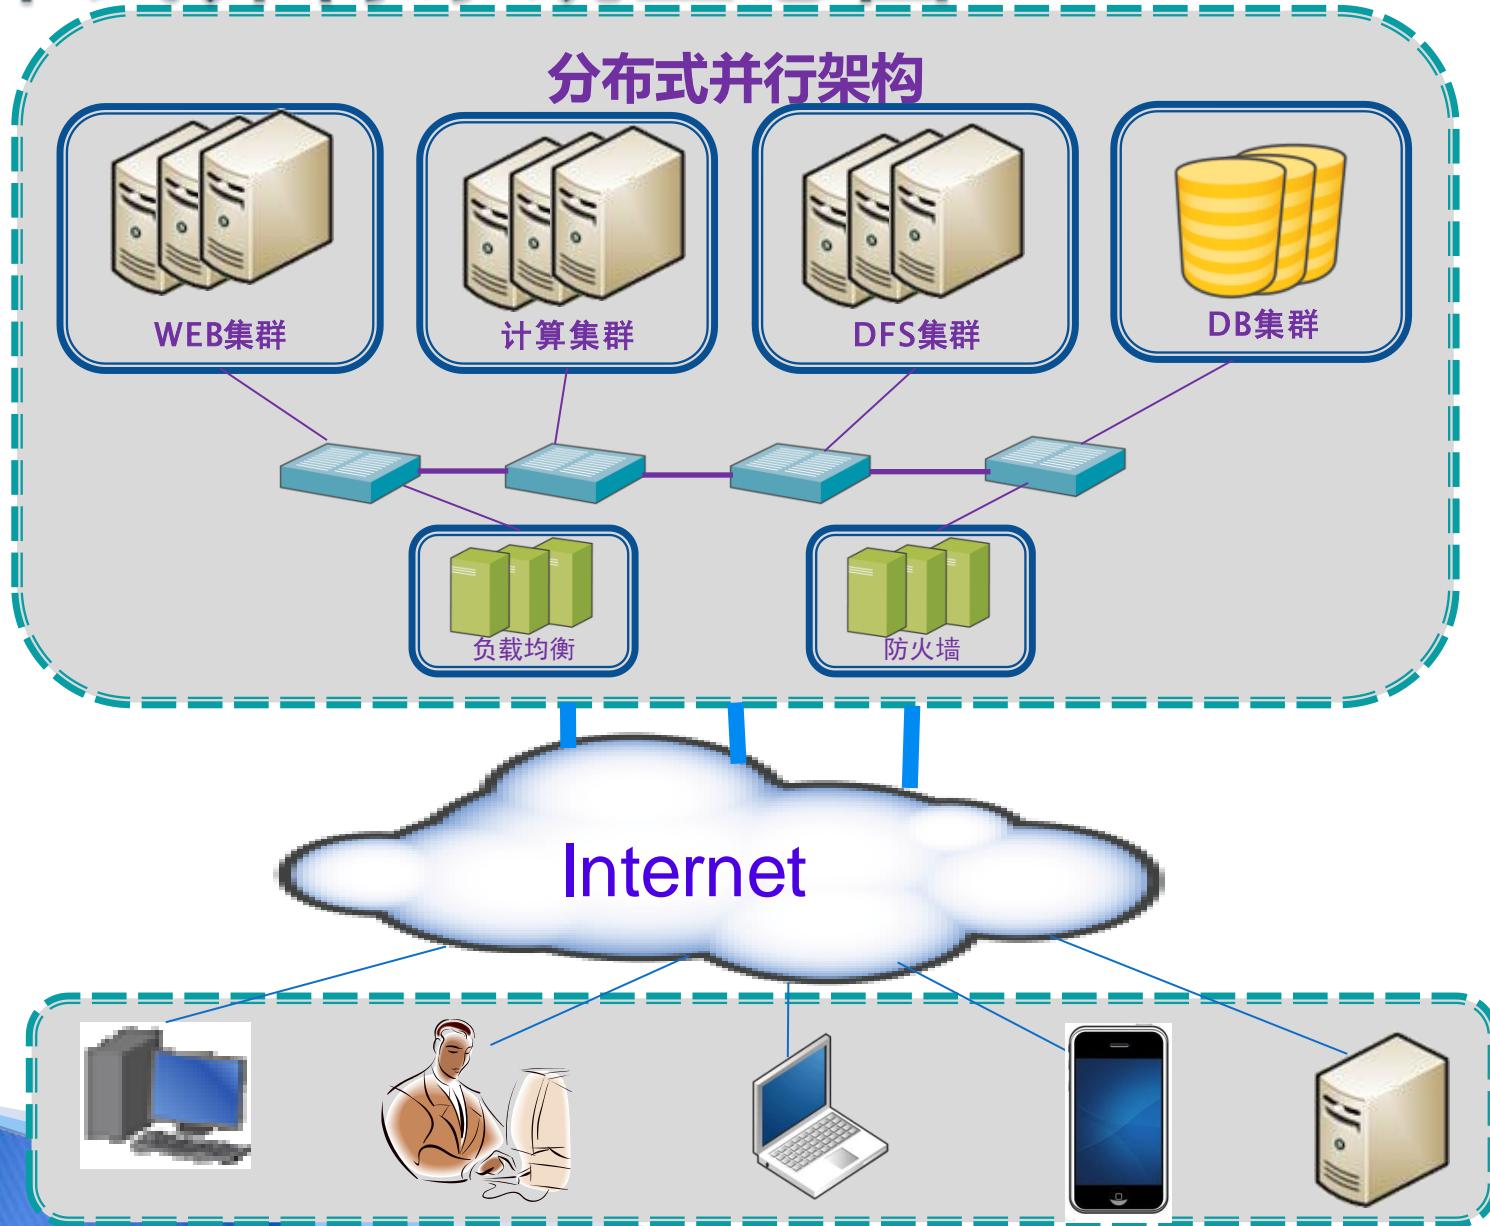
高性能

- 对高并发、低延迟有高要求，保证服务访问快速

高性价比

- 成本价格可控，尽量降低成本

分布式并行系统生态图



分布式并行系统生态图



分布式并行系统设计

➤ 全局（虚拟）关系

- 由所有全局关系组成的子系统

➤ 逻辑关系

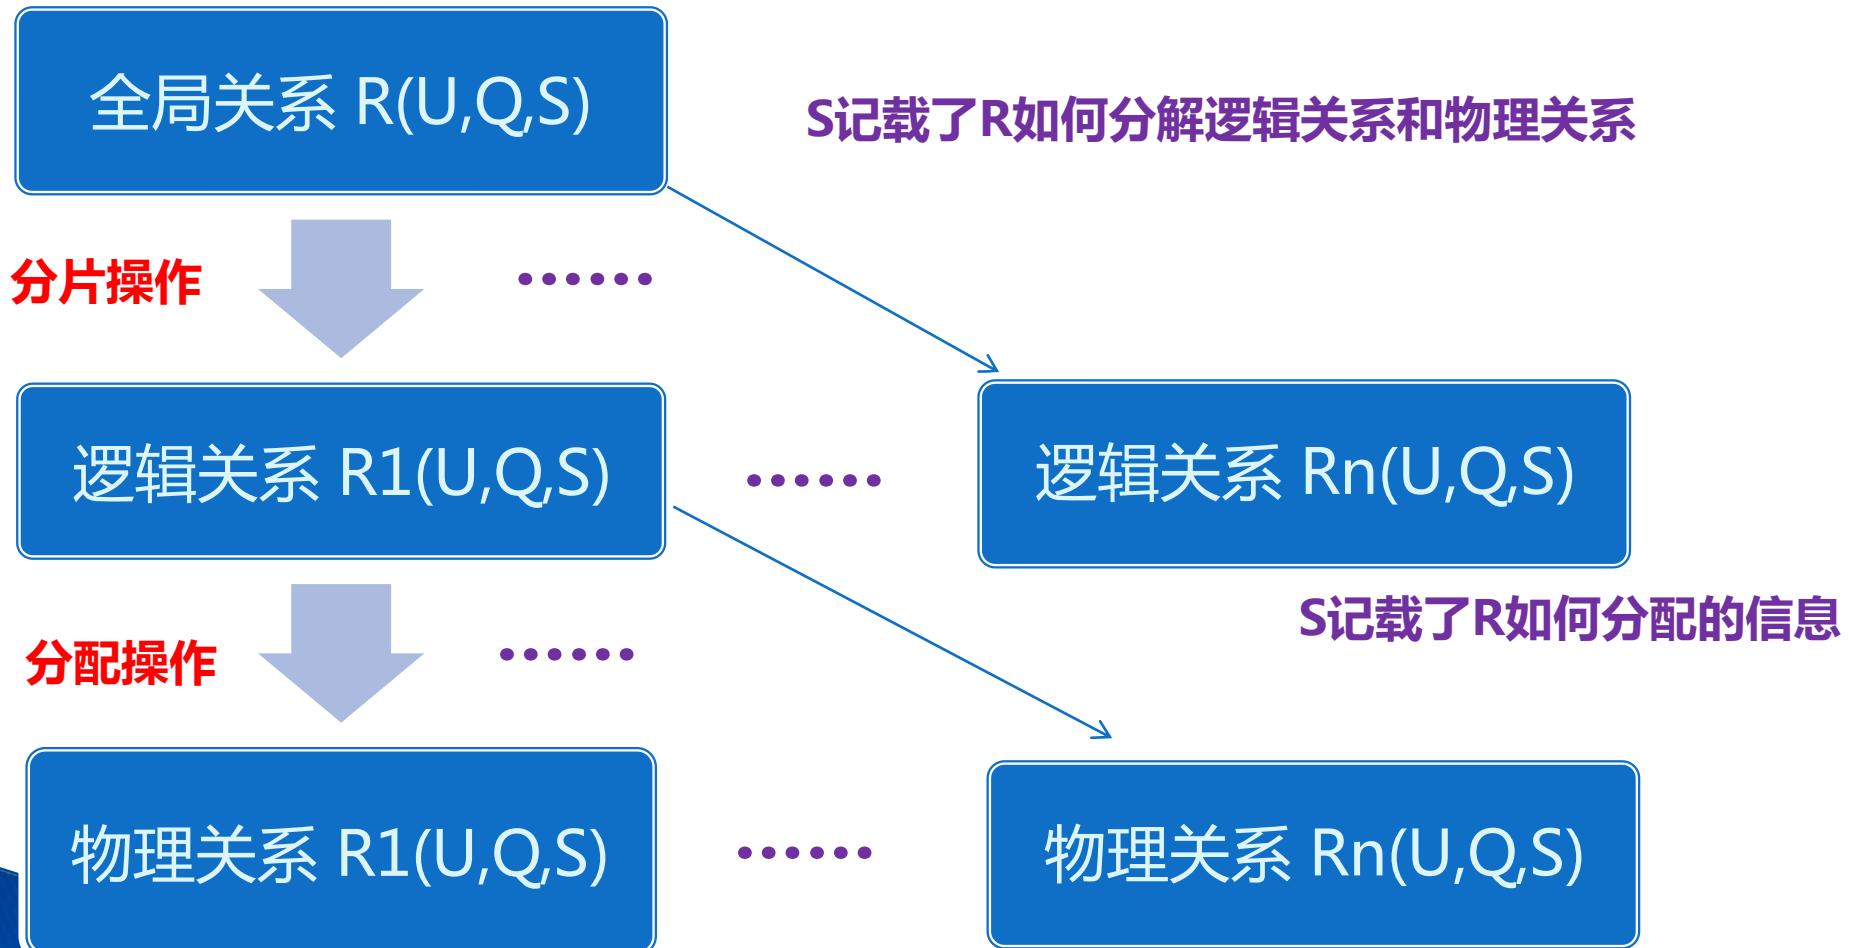
- 由所有逻辑片段组成的子系统

➤ 物理关系

- 由所有物理关系组成的子系统

分布式并行系统设计

- S是有关R被分片和分配的信息的集合



分布式并行系统设计模式

➤ 主从结构

- 简单有效，结构清晰
- 有单点失效问题

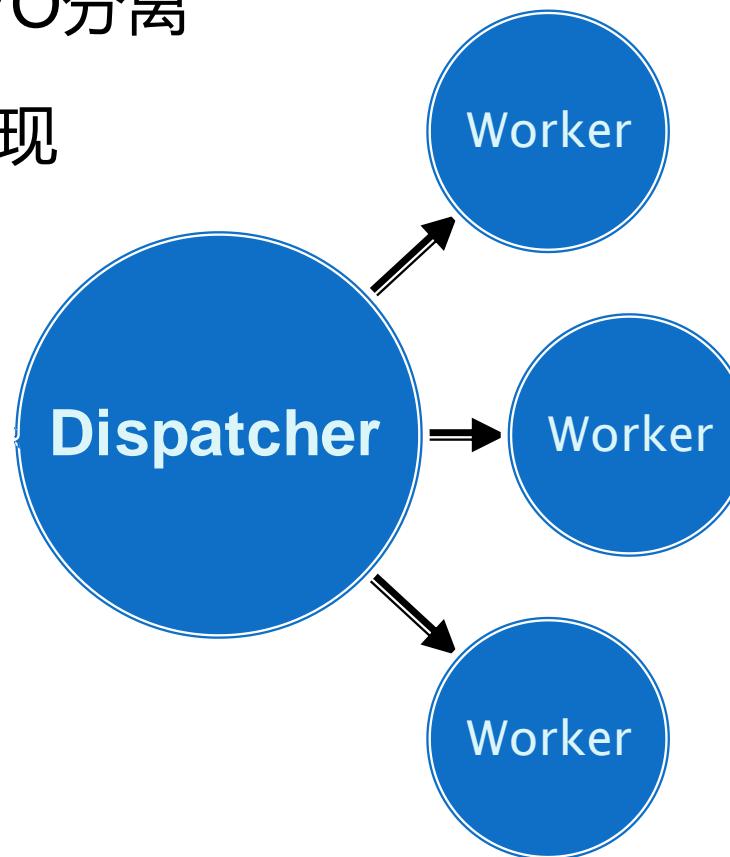
➤ 全对等结构

- 无中心结点，无单点失效
- 很难保证数据一致性

分布式并行系统设计模式

➤ 半同步/半异步 (Half Sync/Half Async)

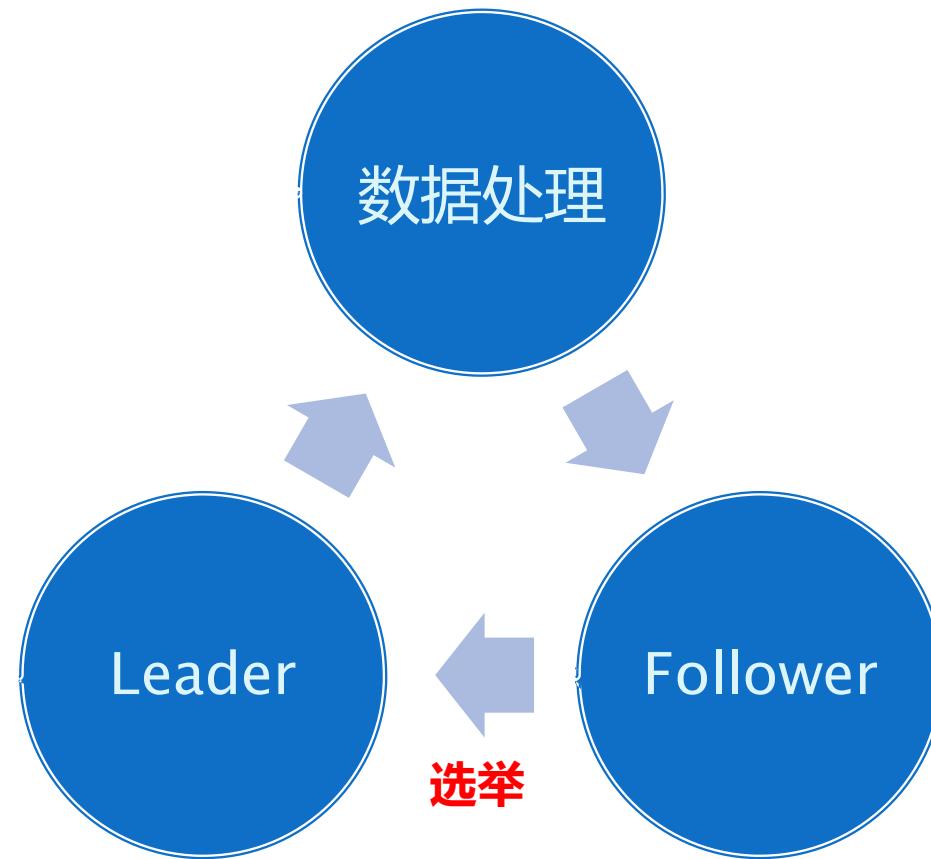
- 同步I/O和异步I/O分离
- 简化并发程序实现



分布式并行系统设计模式

➤ 领导者/追随者模型 (Leader/Followers)

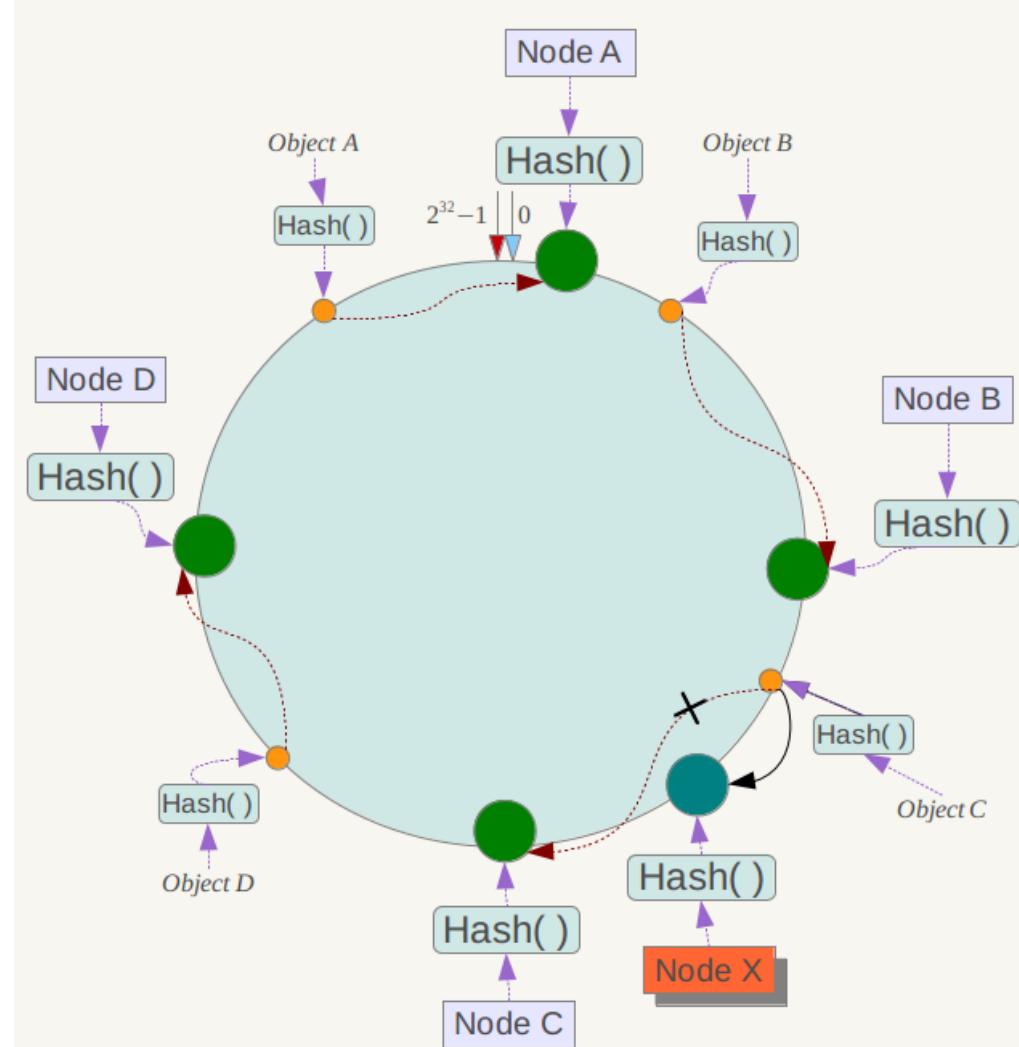
- 无需消息队列
- 无上下文切换



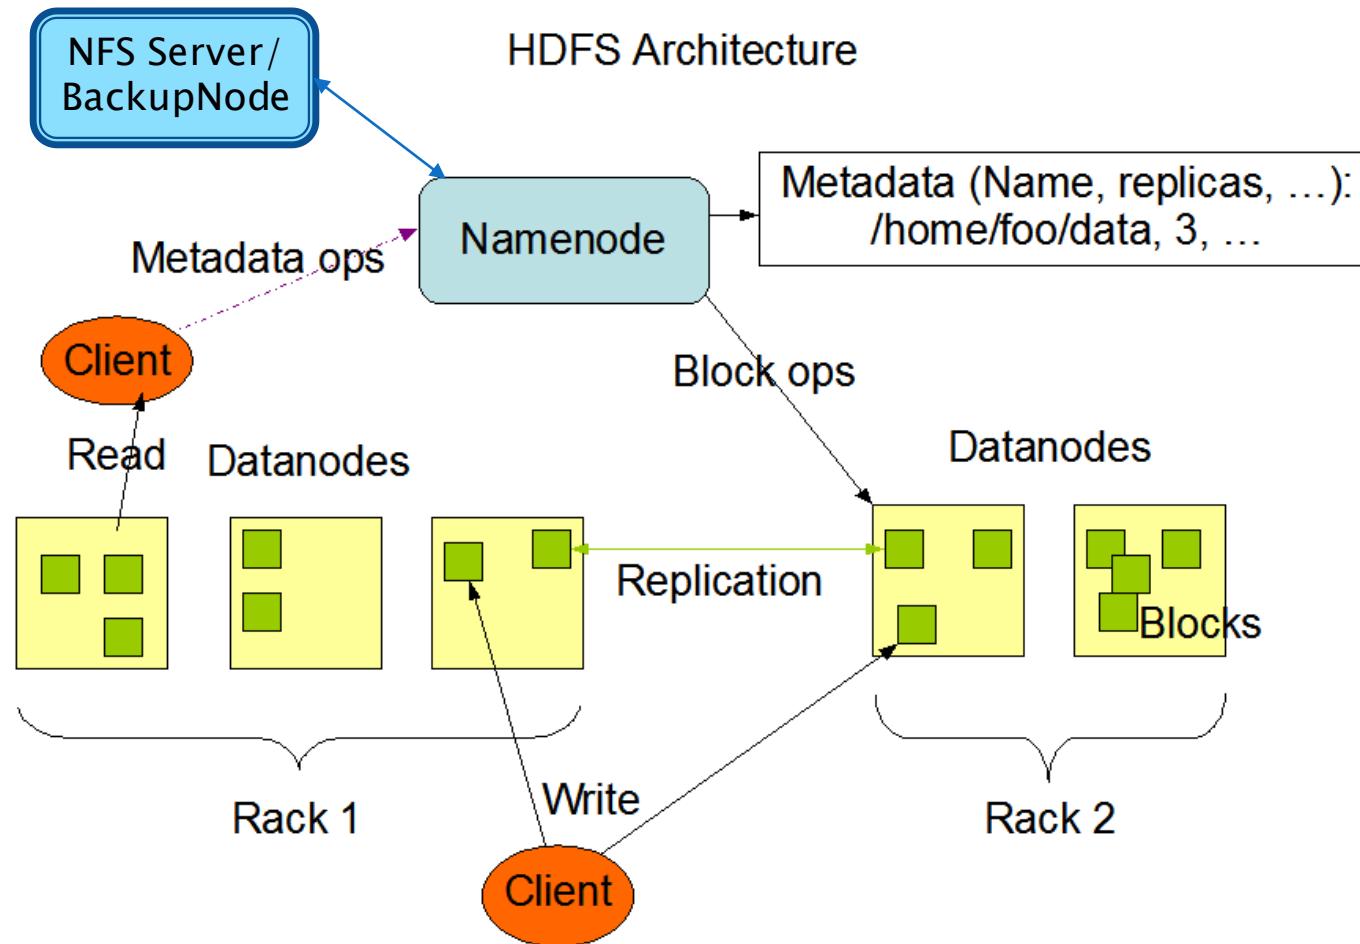
分布式并行系统设计模式

➤ 一致性哈希算法

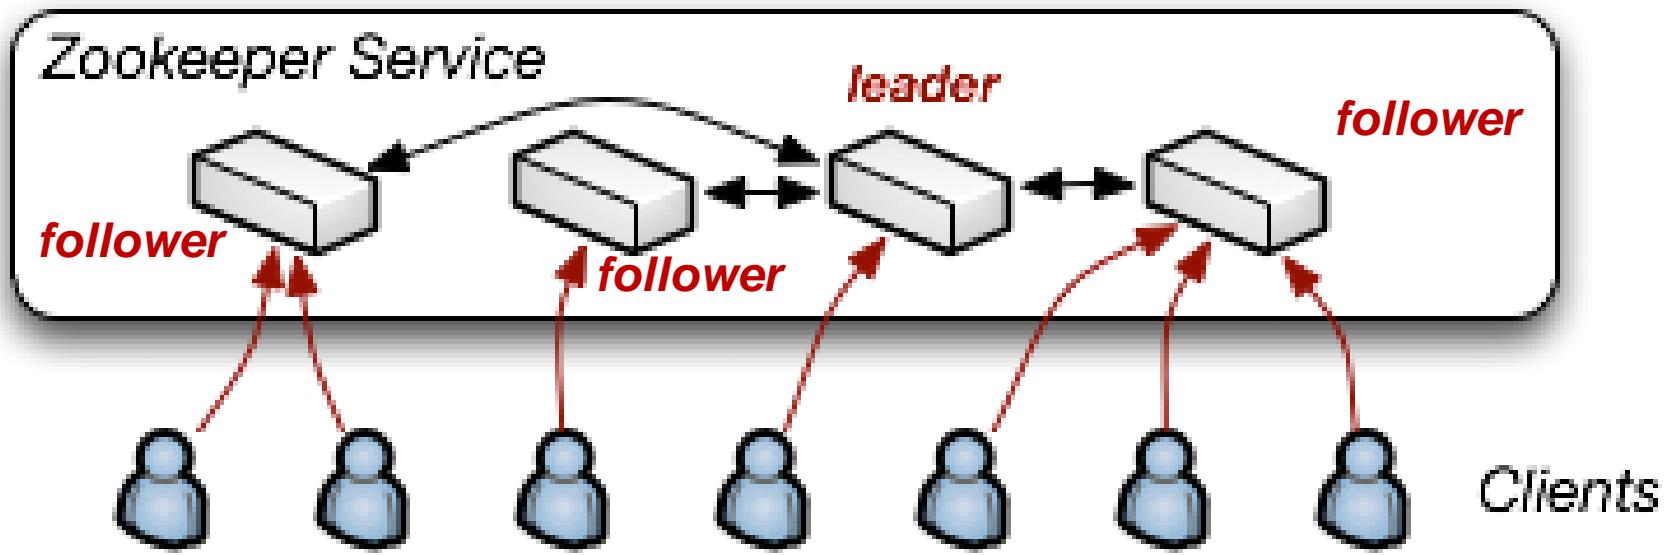
- 将整个哈希值空间组织成一个虚拟的圆环
- 只需重定位环空间中的一小部分数据



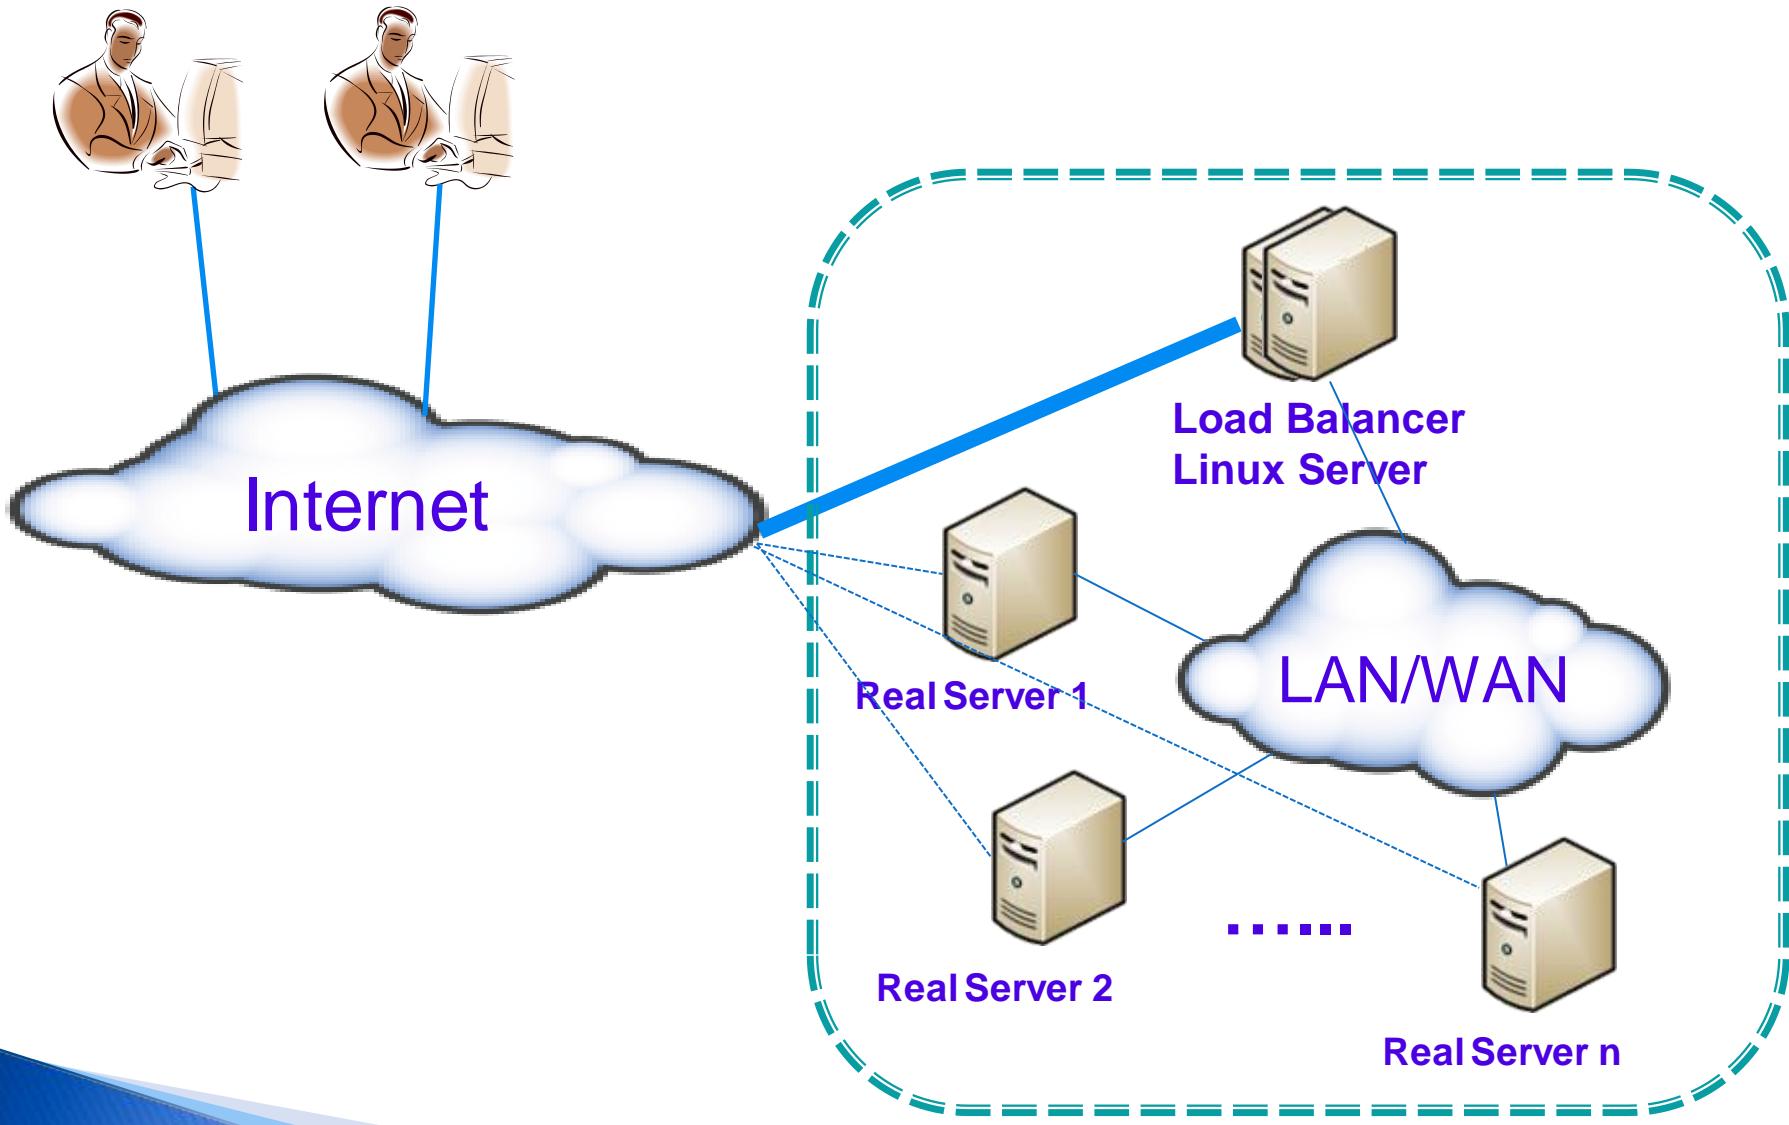
案例分析—分布式文件系统



案例分析—分布式服务框架



案例分析-LVS



单台机器并行设计

➤ CPU

- 多进程多线程
- Parallella : 双核ARM A9加上64核多核浮点加速处理器达到90 GFLOPS

➤ 内存

- 预先分配
- 延时释放
- 避免竞争

单台机器并行设计

➤ 磁盘

- 多磁盘读写

➤ 网卡

- 多网卡设置不同路由

➤ 文件系统

- 设置文件系统缓存值
 - VFS索引节点缓存 (Inode Cache)
 - 目录缓存 (Inode Directory Cache)
 - 缓冲区缓存 (Buffer Cache)
- 设置文件系统预读值

分布式并行系统I/O优化

- ▶ 操作系统优化
 - 关掉不必要的服务
 - 调整关键参数值，如连接数、文件系统格式化分块大小、文件系统预读及缓存值等
- ▶ 网络I/O策略优化
 - 区分带内与带外心跳
 - 控制备份速度
- ▶ 缓存策略优化
 - memcache
 - Redis
 - 缓存命中算法优化

分布式并行系统I/O优化

▶ 同步锁机制优化

- 所有I/O操作的地方尽可能不要加同步锁
- 大锁尽可能拆成小锁

▶ 多路复用I/O优化

- 完成端口 (IOCP)
- Epoll模式
 - LT (level triggered) 方式
 - ET (edge-triggered) 方式

分布式并行系统I/O优化

▶ TCP选项优化

- 发送实时指令
 - TCP_NODELAY
- 缓存区大小设置
 - SO_SNDBUF
 - SO_RCVBUF
- 延迟连接建立
 - TCP_DEFER_ACCEPT

▶ 内存操作优化

- 避免内核空间和用户进程空间内存拷贝
 - sendfile
 - splice and tee
- 预先分配，延时释放

单台机器分布式化设想

- ▶ 众核处理技术
 - 某个CPU坏了不影响系统
- ▶ 多内存条处理技术
 - 某个内存条或者某块内存不可用系统仍然可用
- ▶ 多硬盘处理技术
 - 自动过滤损坏硬盘或磁盘坏道
- ▶ 多网卡处理技术
 - 自动均衡网卡性能

Q & A

谢谢

分布式并行设计无处不在