

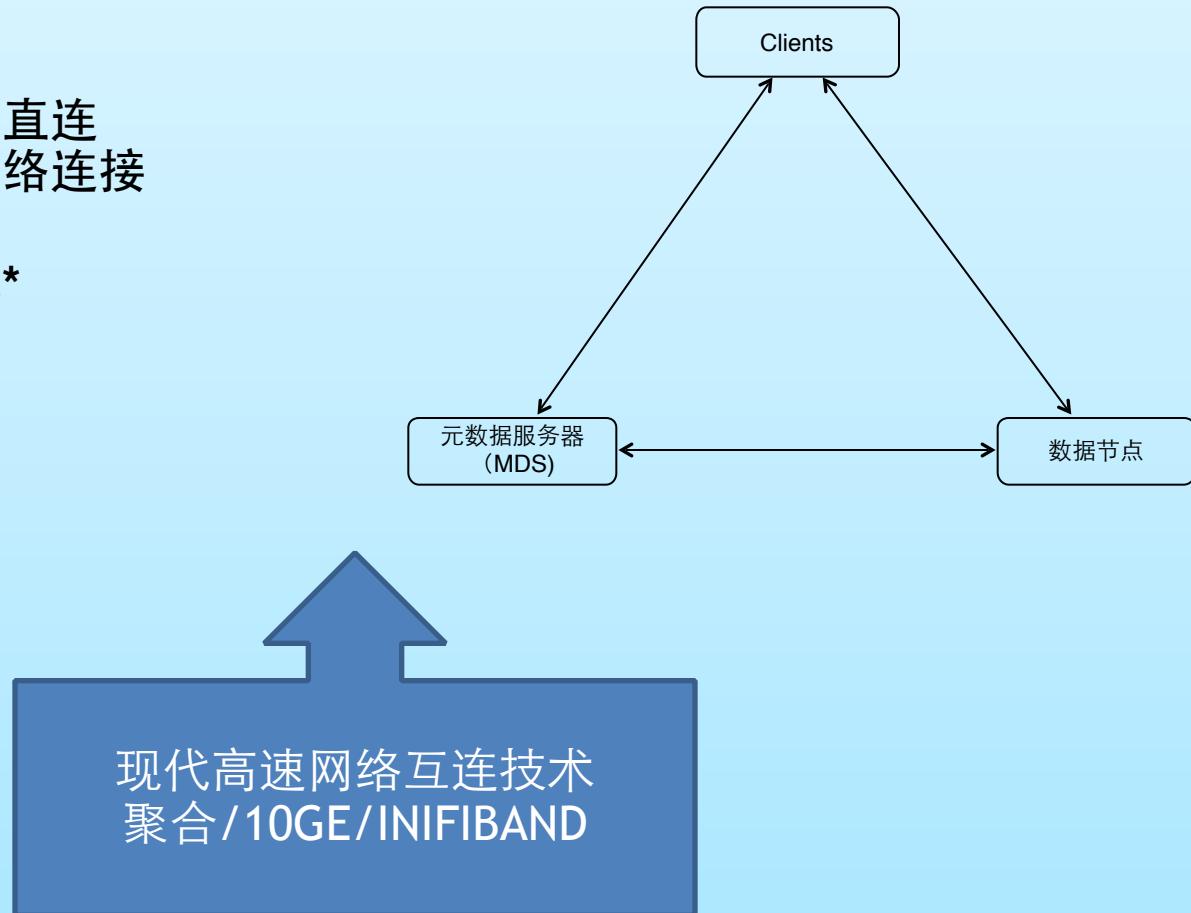
# 分布式文件系统

关键技术

# 分布式文件系统

非本地直连  
通过网络连接

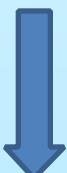
低成本\*  
高性能



# 分类(1)

- C/S文件系统【NFS、CIFS】
  - 多客户端访问同一远程文件系统，文件系统本身不可扩展
  - 架构简单但两台服务器不能同时访问修改，扩展性差，性能有限
- 集群文件系统
- P2P文件系统
- 未来

# 分类(2)

- C/S文件系统
  - 集群文件系统
    - 文件系统可扩展；非对称架构，有元数据系统
    - 常见三种架构管理
      - SAN共享存储架构 (GPFS): 高性能，高成本，扩展性差
      - DAS直连存储架构：数据节点与数据节点混合部署；单点故障，采用副本保障可靠性/可用性
      - 并行文件系统架构: 元数据管理独立；客户端直接访问存储节点数据，高性能，低成本，扩展性好
  - P2P文件系统
  - 未来
- 

# 分类(3)

- C/S文件系统
- 集群文件系统
- P2P文件系统
  - 文件系统可扩展；对称架构，无元数据系统
  - 核心技术：去中心化访问
    - 快速资源定位技术<数据文件对应块寻址时间 us级>
      - 概率路由
      - Chord
      - Pastry
      - Tapetry
      - Byzantine Groups
- 未来
  - 介质(**SSD/DRAM**)、云、SDN

# 元数据管理(并行架构)

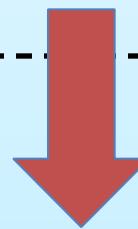
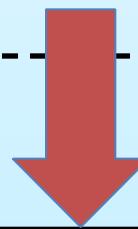
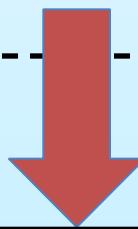
- 集中元数据管理
  - 元数据使用双控或者多控节点提供服务，存在单节点故障、扩展性问题
- 分布式元数据管理
  - 元数据采用全互联全冗余的组网机制，全对称分布式集群设计，扩展性好
- 无元数据管理
  - 元数据服务使用动态子树逻辑分区执行，对变化工作负载进行动态调整、同时保留性能的位置，DC级扩展性

# 分布式文件系统

Posix文件系统

互联网文件系统

S3类存储系统



IBM GPFS  
EMC Isilon  
CephFS  
Lustre  
GlusterFS  
OCFS2  
Oceanstore 9000

GoogleFS  
HDFS  
TaobaoFS  
TencentFS  
Facebook Haystack

Amazon S3  
Openstack Swift  
Oceanstore UDS

# Ceph

CephFS Kernel Object

CephFS FUSE

Ceph FS Library (libcephfs)

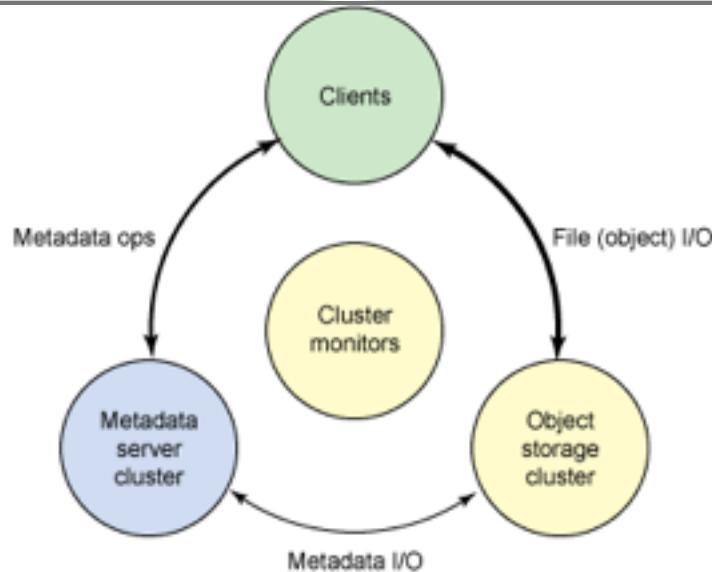
Ceph Storage Cluster Protocol (librados)

OSDs

MDSs

Monitors

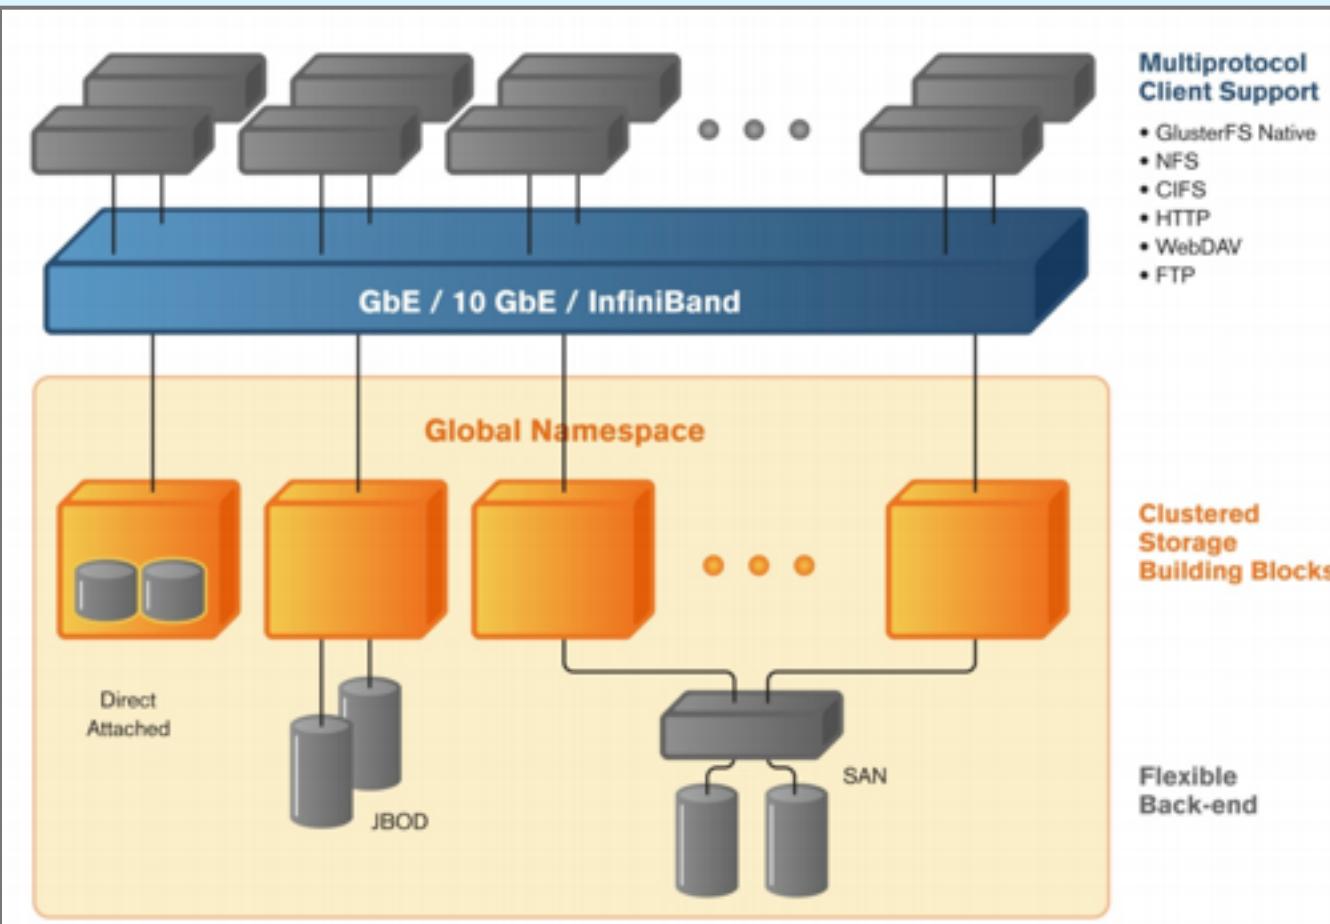
GPL



Ceph 特点：

1. Ceph同时支持块、文件、对象
2. 开源，融入Openstack体系
3. 多种接口：HDFS，NFS，Posix/Fuse
4. 动态子树分割
5. 支持快照

# GlusterFS

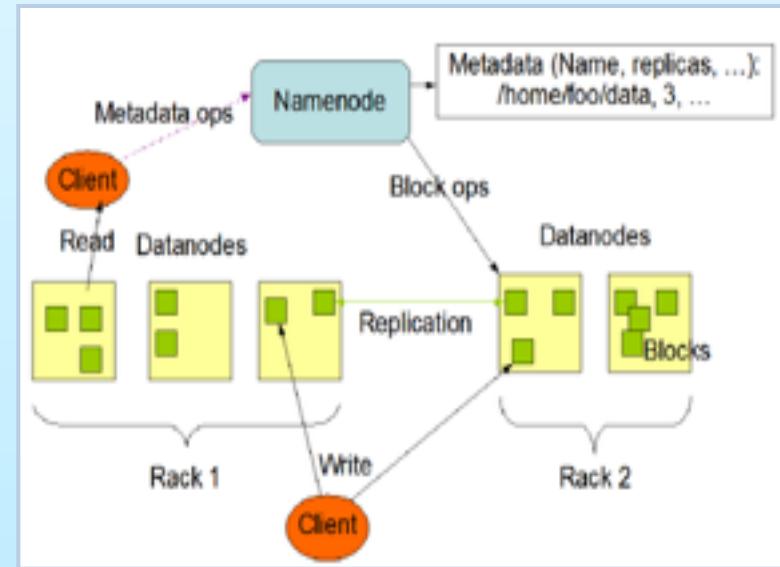
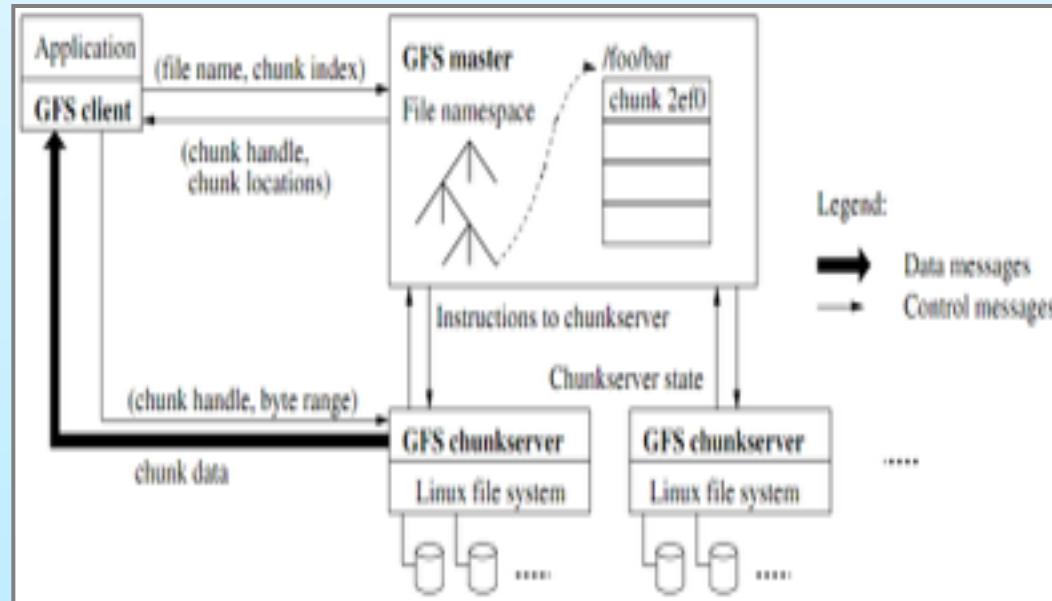


GlusterFS特点：

1. 多种接口，同时支持文件、对象
2. No metadata, Hash定位
3. 支持多种数据布局方式
4. 兼容多种异构存储

GPL

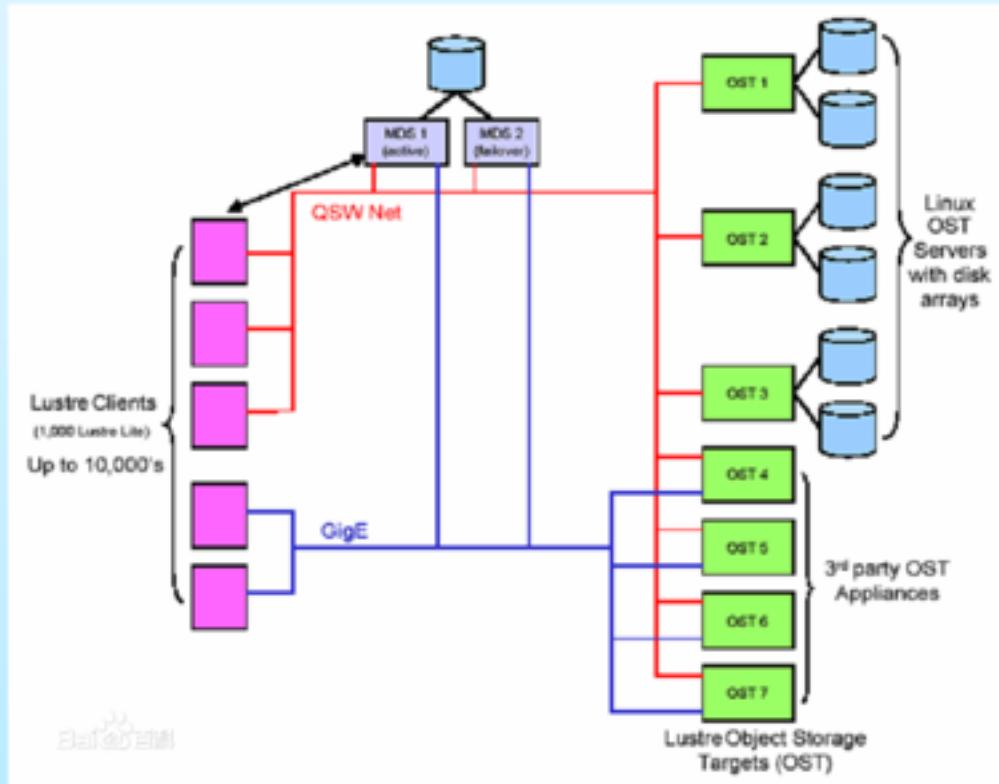
# GoogleFS/HDFS



GoogleFS/HDFS特点：

1. 提供专用的私有API接口，传统业务无法运行
2. 互联网大数据的基础存储平台
3. 定位大数据场景，上层是BigTable/Hbase，MapReduce
4. 定位大文件，高带宽场景

# Lustre



GPL

唯一的命名空间  
上万节点，  
PB容量，  
100GB/S  
容错依靠RAID

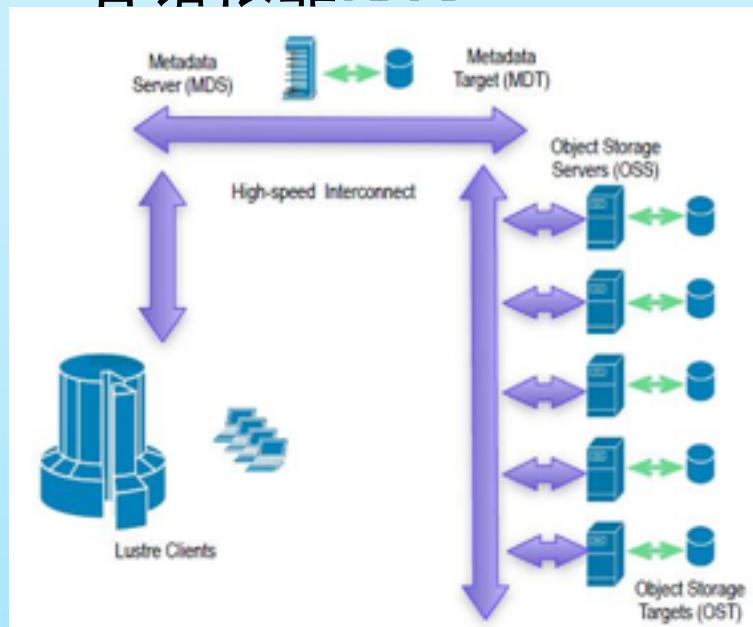
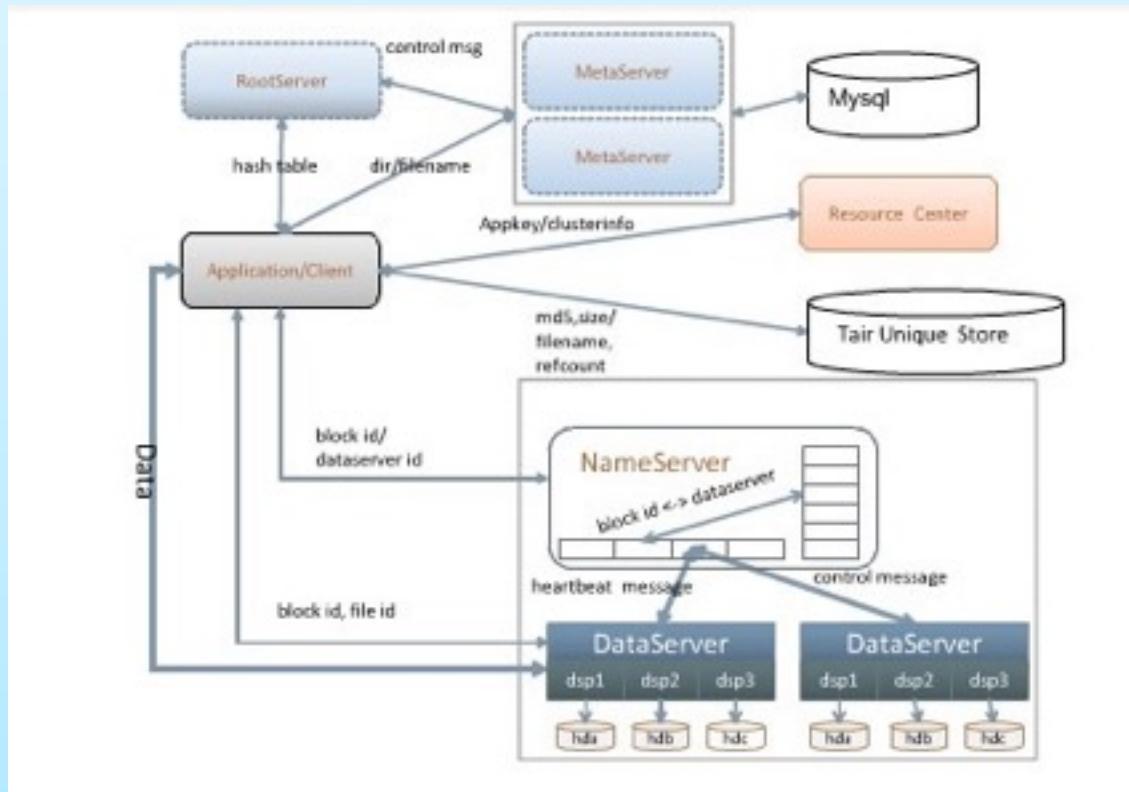


Figure 1: Lustre components.

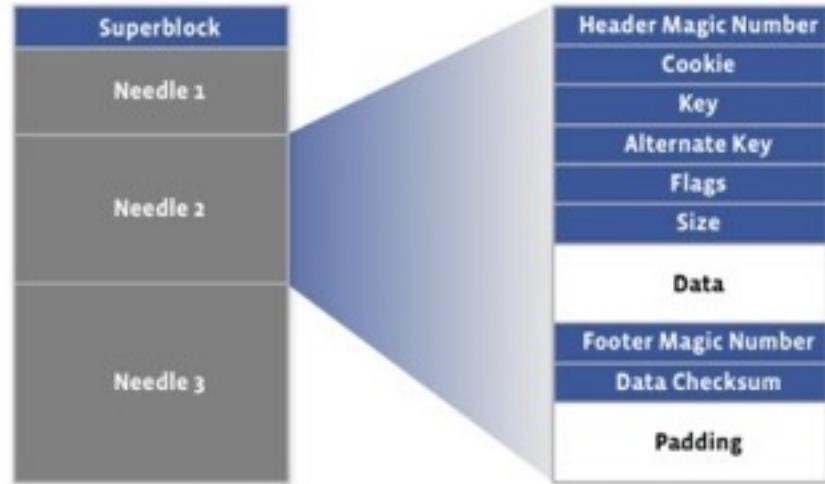
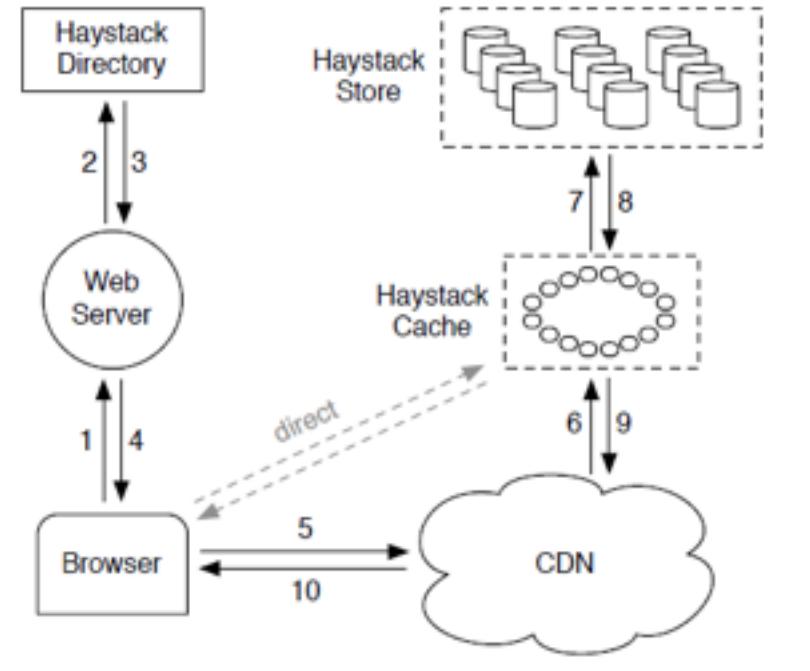
# TaobaoFS



高可扩展  
高可用  
高性能  
面向互联网服务  
支持海量的非结构化数据

海量小文件／扁平化  
数据组织结构/有中心  
节点

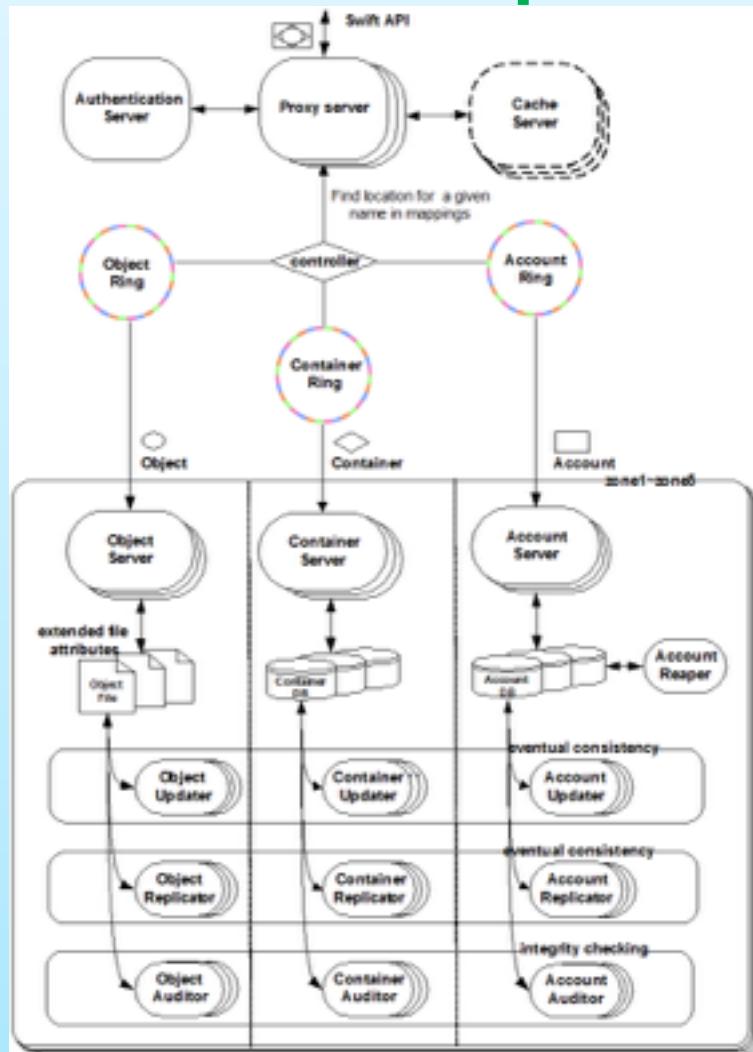
# Facebook Haystack



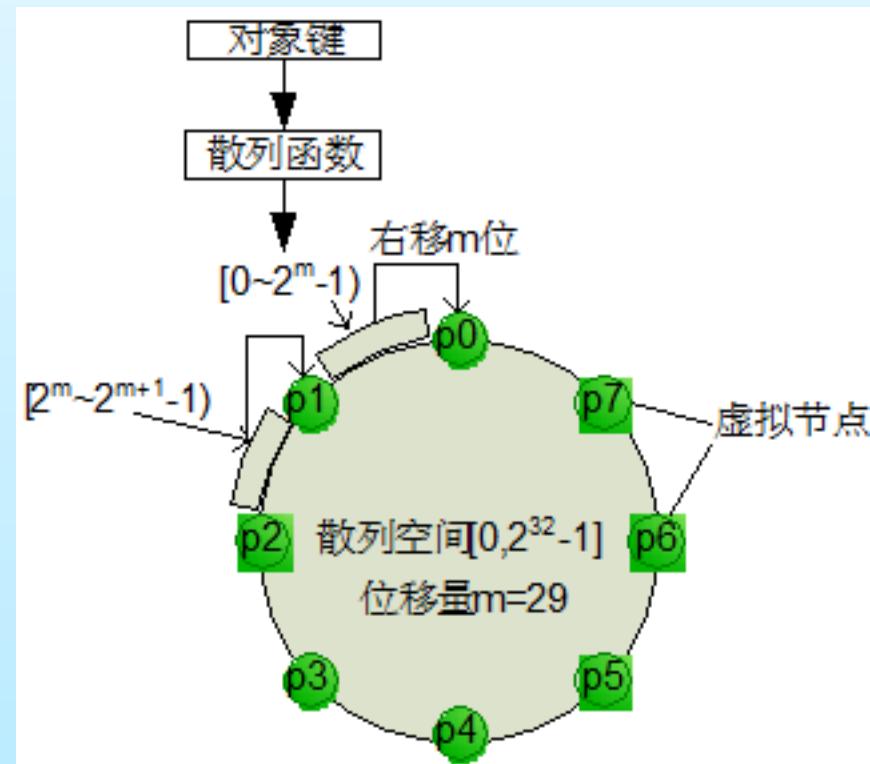
物理卷轴：100GB+  
一次写，多次读，有删除，无修改  
图片存储专有“文件系统”

闭源？

# Openstack Swift



Apache



特点：

1. 提供对象接口
2. 弹性可伸缩
3. 高可用
4. 分布式对象存储
5. 大规模非结构化数据存储

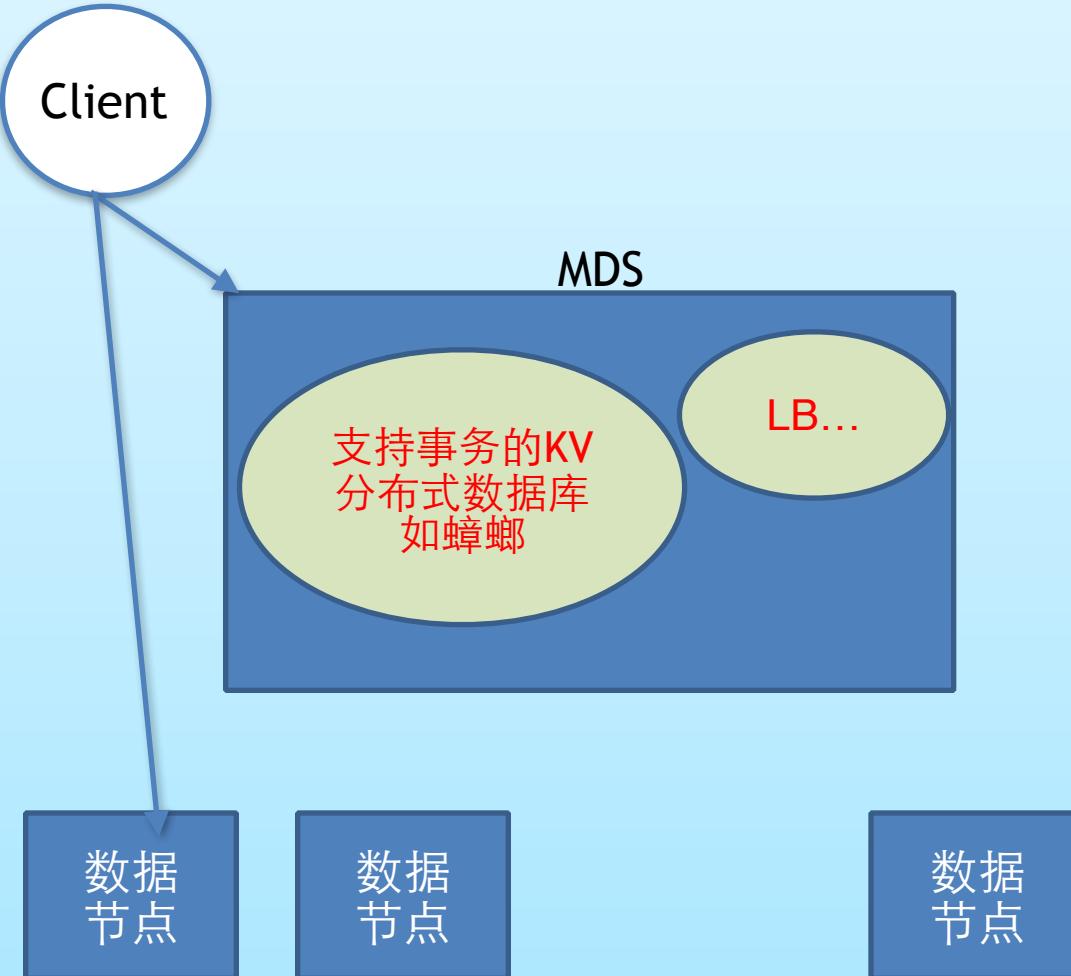
# 开源分布式文件系统

文件系统	POSIX	对象接口	块接口	M/R支持	分布式	适用场景	社区控制	开源协议
<i>Ceph</i>	😊	😊	😊	😊	云	云		<i>GPL</i>
<i>GlusterFS</i>	😊	😊			集群	大数据量 离线应用	Z RESEARCH	<i>GPL</i>
<i>HDFS</i>	😔			😊	集群	大数据／ 大文件	社区	<i>Apache</i>
<i>Luster</i>	😊	😊		😊	集群	<i>HPCC</i>	<i>Intel</i>	<i>GPL</i>
<i>OCFS2</i>	😊				集群	<i>RAC/集群</i>	<i>Oracle</i>	<i>GPL</i>
<i>TaobaoFS</i>	😔		😊		跨地域	互联网／ 小文件	阿里	<i>GPL</i>
<i>Haystack</i>					跨地域	互联网／ 图片	<i>Facebook</i>	?
<i>Swift</i>	😔	😊	😔	😔	云	云/互联网	社区	<i>Apache</i>

# 白蚁分布式文件系统

- 支持POSIX接口和语义
- 支持对象接口
- 支持快照
- 支持云环境部署
- 支持Docker等轻量虚拟化环境
- 支持跨数据中心部署
- 高可靠，大容量，高性能，低价格\*
- Apache商业友好协议
- 社区运作

# 架构

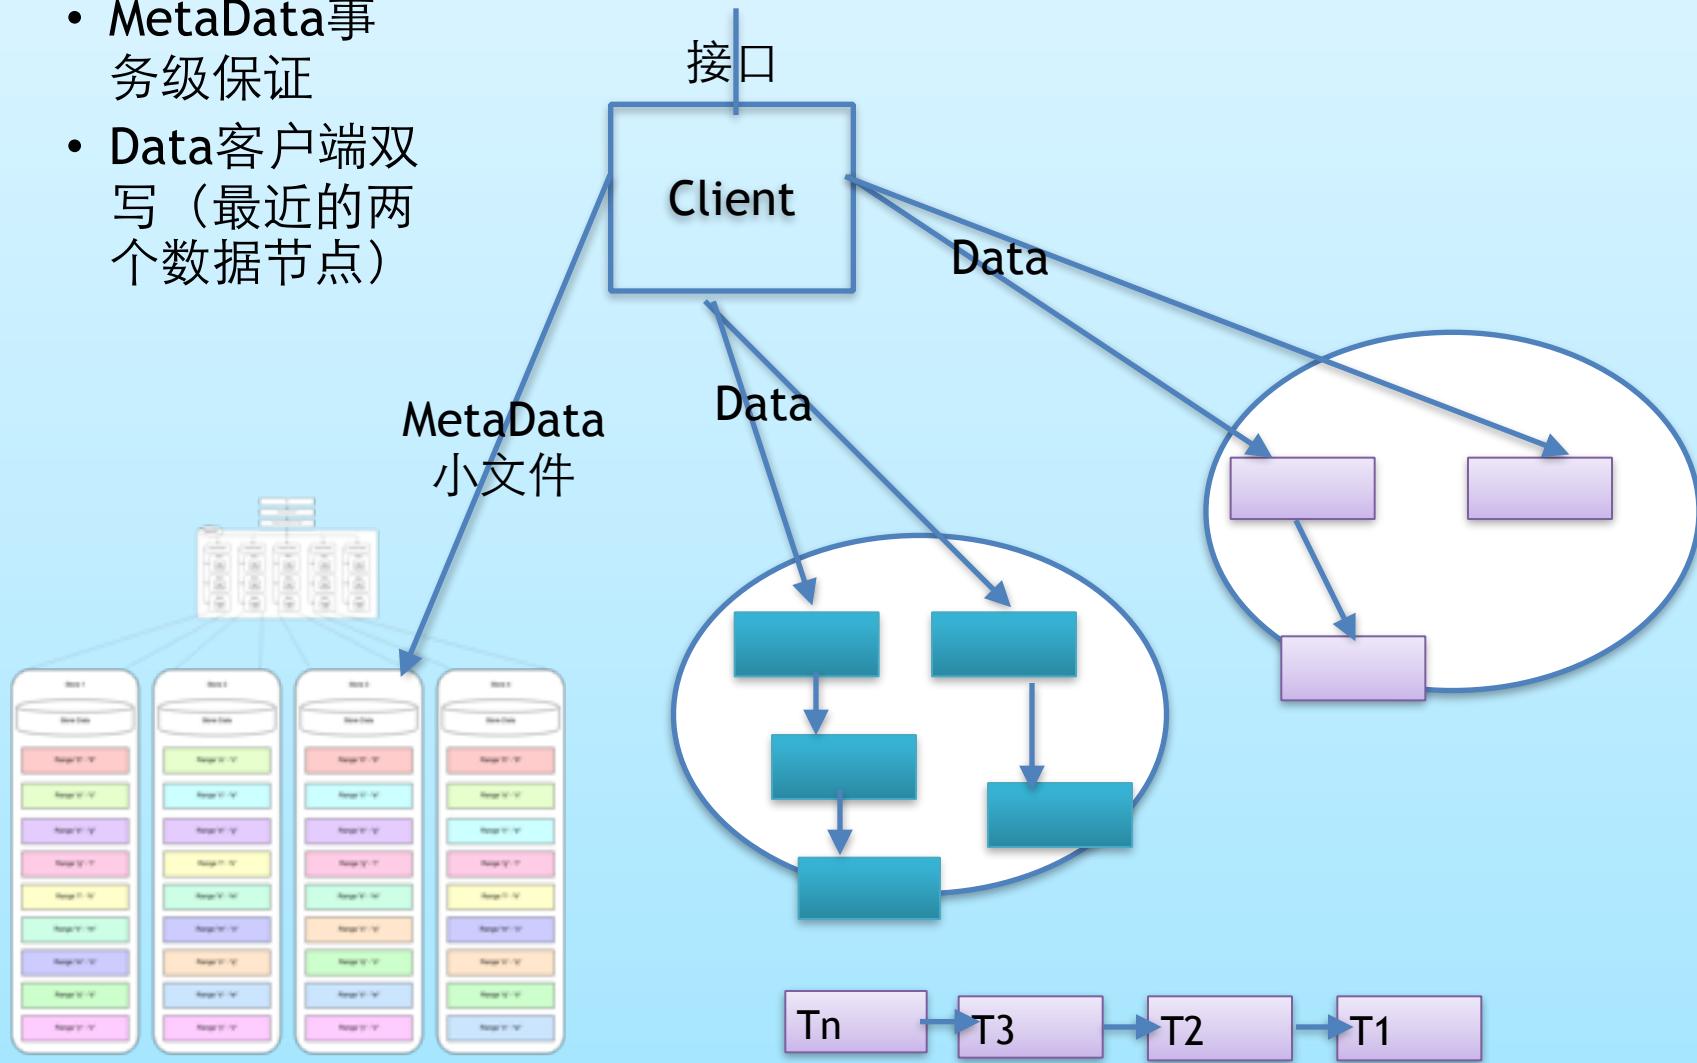


# 特点

- 并行文件系统架构
- 扁平化存储元数据
- 事务级元数据管理
- 用户定义复制管理
- 本地高速缓存优化+CDN

# 主要流程

- MetaData事务级保证
- Data客户端双写（最近的两个数据节点）



# 欢迎加入

- 社区开发

微信号：18500988099