



clover

Clover: A NameNode Cluster Version of HDFS

马灿 中科院计算所 集成应用中心
HiC 2011 @ 12/2/2011

HDFS中NN的问题

- ▶ 现状
 - ▶ 单一NN
 - ▶ 冷启动过程缓慢，可用性低
- ▶ 元数据服务的扩展性
 - ▶ 受制于CPU、内存和网络
 - ▶ 随着系统规模扩展，单节点服务压力大
- ▶ 元数据服务的可用性
 - ▶ 单一故障点，需要外部HA组件



已有的NN改进方法

▶ HDFS Federation

- ✓ 多个NN，分离独立的名字空间
- ✓ 共享DN存储池
- x 缺乏全局名字空间，互相共享数据困难

▶ HDFS-DNN

- ✓ 使用HBase存储元数据
- x 原型系统，无详细信息

▶ HDFS2

- ✓ 分离名字空间与块管理
 - ▶ 分布式文件管理，集中式名字空间
- x 名字空间服务的扩展性受限，不支持目录rename




Clover的NN Cluster方案


- ▶ 分拆名字空间与块管理到集群上
 - ▶ 提供全局名字空间
 - ▶ 使用分布式日志确保mkdir, rename, delete等操作的一致性
 - ▶ DN块汇报分流
- ▶ 元数据共享存储池
 - ▶ 提供基于多副本的元数据高可靠存储
 - ▶ 在NN和BackupNode之间共享元数据文件
 - ▶ 支持分布式事务的日志
- ▶ 高可用方法
 - ▶ 元数据集群的多机互相热备
 - ▶ 全局检查点，缩短冷启动时间



Bird's-eye View



Clover NameNode Cluster




NameNode

DataNode




分布式名字空间

- ▶ 全局目录表（集中式or分布式）
 - ▶ 存储所有目录到唯一ID(dir_uid)的映射关系
- ▶ 基于目录的分布
 - ▶ dir_uid → 虚拟节点 → 物理节点
- ▶ 支持目录的rename




元数据文件的共享、可靠存储

- ▶ 由NN集群构建共享存储池
- ▶ 在文件级别自动复制
 - ▶ 一个local, 多个remove
- ▶ 三种文件访问模式
 - ▶ FSImage → 大块顺序读写
 - ▶ Editlog → 小粒度的追加写、大块读
 - ▶ WAL → 小粒度并发追加写、并发读
- ▶ 性能要求
 - ▶ FSImage → 高读写带宽 → Pipeline
 - ▶ Editlog/WAL → 低延迟 → Sync to local disk + remote mem; Async to remote disk



基于共享存储的快速分布式事务




事务执行结果确认点

全局检查点


外部检查点工具触发

步骤

- 全局Barrier同步
- 所有的NN清空信道 (Chandy-Lampport算法)
- 所有的NN向Editlog写入Barrier标记
- 外部检查点工具从共享存储池中读取**每个**NN的元数据文件合并FSImage和Editlog, 直到遇到标记
 - 写回新的FSImage



多机间互相热备



多机间互相热备

- ▶ 假设节点年化故障率为 α ，系统冷启动时间为 T
- ▶ HDFS双机热备
 - ▶ 单机故障，热备生效→故障率： α ； $MTTR \approx 0$
 - ▶ 双机故障，冷启动→故障率： α^2 ； $MTTR = T$
- ▶ Clover热备 (N 节点)
 - ▶ 单机故障，热备生效→故障率： $N \cdot \alpha$ ； $MTTR \approx 0$
 - ▶ 双机故障，冷启动→故障率： $N \cdot \alpha^2$ ； $MTTR = T/N$
 - ▶ 全系统故障→故障率： α^N ； $MTTR = T/N$

通过热备提高了系统的可用性，
同时降低了系统平均故障恢复时间（冷启动时间）



Who are we?

- ▶ 中科院计算所 集成应用中心 并行数据组
- ▶ 王伟平 (wpwang@ncic.ac.cn) 副研究员
- ▶ 马灿
 - ▶ Twitter: @nkmacana
 - ▶ Email: ml.macana@gmail.com (G+: [+Can Ma](#))
 - ▶ Blog: <http://macan.posterous.com>
 - ▶ Github: <http://github.com/macan>
- ▶ 周江 (zhoujiang@ncic.ac.cn)
- ▶ 王有为 (wangyouwei@ncic.ac.cn)



Thanks!
Q & A



How to lookup a file?

▶ Input

- ▶ File's pathname: F (e.g. `/usr/macan/hello/all`)

▶ Client Steps


- ▶ Get dirname and basename: $D(F) = \text{"/usr/macan/hello"}$, $B(F) = \text{"all"}$
- ▶ Get dir_uuid: Send request to $H_1(D(F))$ w/ $D(F)$
- ▶ Get metadata: Send request to $H_2(\text{dir_uuid})$ w/ $B(F)$

▶ Pros and Cons

- ▶ Rename friendly
- ▶ 2RTT
 - ▶ $D(F) \rightarrow \text{dir_uuid}$ can be cached!



How complex operations are always right?



Distributed TX w/ Shared Storage Pool