

2000 元的机械硬盘 > 3000 元的固态硬盘?

A.K.A. 镜像站 ZFS 调优实践

iBug @ USTC

2024 年 8 月 17 日
南京大学 开源软件论坛

USTC Mirrors

- 日均服务量：（2024-05 ~ 2024-06）
 - 出流量 ~36 TiB
 - HTTP 请求数 17M, 响应流量 19 TiB
 - Rsync 请求数 147.8K (21.8K) , 输出流量 10.3 TiB
- 极限情况的仓库容量：
 - HTTP 服务器 (XFS) : 63.3 TiB / 66.0 TiB (96%, 2023-12-18)
 - Rsync 服务器 (ZFS) : 42.4 TiB / 43.2 TiB (98%, 2023-11-21)

背景

- HTTP 服务器：
 - 2020 年下半年搭建
 - 10 TB  × 12
 - 2 TB  × 1
 - XFS on LVM on HW RAID
 - 考虑到 XFS 不能缩，VG 留了 free PE
- Rsync 服务器：
 - 2016 年下半年搭建
 - 6 TB  × 12
 - 240 GB  × 2 + 480 GB  × 1 (Optane 900p)
 - RAID-Z3 (8 data + 3 parity + 1 hot spare)
 - 全默认参数 (除了 `zfs_arc_max`)

硬盘 I/O 日常 > 90%，校内下载 iso 不足 50 MB/s



USTC 镜像站两台服务器在 2024 年 5 月期间的磁盘负载

ZFS


- 单机存储的终极解决方案
- 集 RAID、LVM、FS 于一体
- 所有数据都有 checksum
- ~~Fire and forget~~
- 好多参数啊

前期学习与实验

- ~~从(另一个)老师那嫖了点盘~~装上了 ZFS, 用于研 究 学 习
- I/O 负载来源? ~~土 PT 站~~
- 练习时长两年半的成果: ↑ 1.20 PiB, ↓ 1.83 TiB

重要学习资料:


- [Chris Siebenmann's blog](#)
- [OpenZFS Documentation](#)
- iBug's blog: [Understanding ZFS block sizes \(ibug.io/p/62\)](#)
 - 以及这篇 blog 底下的众多参考文献



好像给什么奇怪的东西加入了 Grafana

镜像站

- 提供文件下载服务
- ~~也提供「家庭宽带上下行流量比例平衡」服务~~
- 读多写少，并且几乎所有操作都是整个文件顺序读写
- 少量的数据损坏没啥不良后果



2024 年 8 月 USTC 镜像仓库内的文件大小分布
其中中位数为 9.83 KiB，平均大小为 1.60 MiB

重建 Rsync 服务器

- RAID-Z3 的 overhead 较高, 而且拆成两组 RAID-Z2 = 两倍的 IOPS
- 镜像站调优计划:
 - recordsize=1M : 反正都是全文件顺序读
 - compression=zstd : 至少可以压掉 > 1M 文件的 padding
 - OpenZFS 2.2 将 early abort 机制推广到了 Zstd 3+, 不必担心性能问题
 - xattr=off : 谁家镜像需要 xattr?
 - atime=off, setuid=off, exec=off, devices=off : 开着干啥?
 - secondarycache=metadata : Rsync 就别来消耗固态寿命了
- Danger Zone:
 - sync=disabled : 囤到 zfs_txg_timeout 再写盘
 - redundant_metadata=some : 偶尔坏个文件也没事
- Full version: [LUG @ USTC Documentation](#)

ZFS 参数

- 290+ 参数不能个个都学习嘛 (感谢 Aron Xu @ BFSU)

- ARC 容量:

```
# Set ARC size to 160-200 GiB, keep 16 GiB free for OS
options zfs zfs_arc_max=214748364800
options zfs zfs_arc_min=171798691840
options zfs zfs_arc_sys_free=17179869184
```

- ARC 内容:

```
# Favor metadata to data by 20x (OpenZFS 2.2+)
options zfs zfs_arc_meta_balance=2000

# Allow up to 80% of ARC to be used for dnodes
options zfs zfs_arc_dnode_limit_percent=80
```


- I/O 队列深度:

```
# See man page section "ZFS I/O Scheduler"
options zfs zfs_vdev_async_read_max_active=8
options zfs zfs_vdev_async_read_min_active=2
options zfs zfs_vdev_scrub_max_active=5
options zfs zfs_vdev_max_active=20000
```

- Full version: [LUG @ USTC Documentation](#)

重建成果

- 略感惊喜的压缩率：39.5T / 37.1T = 1.07x
 - 正确用法： `zfs list -po name,logicalused,used`
 - 实际压缩率：1 + 6.57% (-2.67 TB / -2.43 TiB)
 - ~~等于删了 9 份微信数据~~
- 合理的磁盘 I/O



重建前后 Rsync 服务器的磁盘负载与空闲空间比较

HTTP 服务器

- 硬件 RAID + LVM + XFS + Kernel page cache (开箱即用?)
- SSD? LVMCache!
 - 1M extents? Block size? Algorithm?
 - 💀 GRUB2
 - 💀 "oldssd"
- XFS 不能缩, 所以 VG 和 FS 两层都要留空间备用



重建前 HTTP 服务器采用的 LVMcache 方案的命中率

如法炮制


- 体验一下更加先进的 kernel: 6.8.8-3-pve (无需 DKMS 哦)
- 重建为两组 RAID-Z2, 开压缩
 - 面向 HTTP 用户的服务器, 所以 secondarycache=all (放着不动)
 - 更好的 CPU, 所以 compression=zstd-8
- 更快的 zfs send -Lcp : 36 小时倒完 50+ TiB 仓库
- 压缩率: 1 + 3.93% (-2.42 TB / -2.20 TiB)



重建前后两台服务器的磁盘负载比较
左边为重建前，中间为仅 Rsync 服务器重建后，右边为两台服务器均重建后的负载



两台服务器的 ZFS ARC 命中率



两台服务器重建后稳定的磁盘利用率

杂项

ZFS 压缩率

NAME	LUSED	USED	RATIO
pool0/repo/crates.io-index	2.19G	1.65G	3.01x
pool0/repo/elpa	3.35G	2.32G	1.67x
pool0/repo/rfc	4.37G	3.01G	1.56x
pool0/repo/debian-cdimage	1.58T	1.04T	1.54x
pool0/repo/tldp	4.89G	3.78G	1.48x
pool0/repo/loongnix	438G	332G	1.34x
pool0/repo/rosdistro	32.2M	26.6M	1.31x

我数学不好: [🐱 openzfs/zfs#7639](#)

ZFS 压缩量

NAME	LUSED	USED	DIFF
pool0/repo	58.3T	56.1T	2.2T
pool0/repo/debian-cdimage	1.6T	1.0T	549.6G
pool0/repo/opensuse	2.5T	2.3T	279.7G
pool0/repo/turnkeylinux	1.2T	1.0T	155.2G
pool0/repo/loongnix	438.2G	331.9G	106.3G
pool0/repo/alpine	3.0T	2.9T	103.9G
pool0/repo/openwrt	1.8T	1.7T	70.0G

Grafana I/O 统计

```
SELECT
  non_negative_derivative(sum("reads"), 1s) AS "read",
  non_negative_derivative(sum("writes"), 1s) AS "write"
FROM (
  SELECT
    first("reads") AS "reads",
    first("writes") AS "writes"
  FROM "zfs_pool"
  WHERE ("host" = 'taokystrong' AND "pool" = 'pool0') AND $timeFilter
  GROUP BY time($interval), "host"::tag, "pool"::tag, "dataset"::tag fill(null)
)
WHERE $timeFilter
GROUP BY time($interval), "pool"::tag fill(linear)
```

跑得有点慢（毕竟要先 GROUP BY 每个 ZFS dataset 再一起 sum）

I/O 带宽：把里层的 reads 和 writes 换成 nread 和 nwritten 即可



- 如何用机械盘跑出平均 15K、最高 50K 的 IOPS?
- 把 ~~ARC hit~~ 算进去

灵车时间

Proxmox Kernel

- $\approx$ Ubuntu Kernel
- 💀 Rsync 容器
- security/apparmor/af_unix.c ???
- [LUG Documentation: AppArmor](#)

```
dpkg-divert --package lxc-pve --rename --divert /usr/share/apparmor-features/features.stock --add /usr/share/apparmor-features/features  
wget -O /usr/share/apparmor-features/features https://github.com/proxmox/lxc/raw/master/debian/features
```


Dedup!

```
zfs create -o dedup=on pool0/repo/zerotier
```

```
# zdb -DDD pool0  
dedup = 4.93, compress = 1.23, copies = 1.00, dedup * compress / copies = 6.04
```

效果倒是不错，但是不想像 ZFS dedup 这么灵怎么办？

jdupes

```
# post-sync.sh
# Do file-level deduplication for select repos
case "$NAME" in
  docker-ce|influxdata|nginx|openresty|proxmox|salt|tailscale|zerotier)
    jdupes -L -Q -r -q "$DIR" ;;
esac
```


jdupes 效果

Name	Orig	Dedup	Diff	Ratio
proxmox	395.4G	162.6G	232.9G	2.43x
docker-ce	539.6G	318.2G	221.4G	1.70x
influxdata	248.4G	54.8G	193.6G	4.54x
salt	139.0G	87.2G	51.9G	1.59x
nginx	94.9G	59.7G	35.2G	1.59x
zerotier	29.8G	6.1G	23.7G	4.88x
mysql-repo	647.8G	632.5G	15.2G	1.02x
openresty	65.1G	53.4G	11.7G	1.22x
tailscale	17.9G	9.0G	9.0G	2.00x

只要 ZFS 用得好

- 妈妈再也不用担心我的硬盘分区
- 机械硬盘 ~~比西方的固态硬盘跑得还快~~
- 成为第一个不再**羡慕** TUNA 全闪的镜像站
- 免费的额外容量
 - Dedup 会员红包
- 碎片率?

谢谢！

本页面的链接：[🔗 ibug.io/p/72](https://ibug.io/p/72)

友情链接：2023 年南京大学报告：[🔗 ibug.io/p/59](https://ibug.io/p/59)

