

那些年我们做镜像站踩过的坑

Slide 0: 封面页

标题: 那些年我们做镜像站踩过的坑

副标题: FMA 开源镜像站实录

演讲者: FMA 开源镜像站团队主设计师 Avrova Donz

日期: 2025/12/24

Slide 1: 目录

- 明确问题: 我们踩过的坑
- 业界参考: 存储分层框架
- 自身方案: FMA 架构演进
- 经验验证与致谢

第一部分: 明确问题 (纯事实)

Slide 2: 问题清单 (事实陈述)

1. **overlayfs 踩坑:** RevyOS 硬链接场景使用 squashfs+overlayfs, inode 耗尽
2. **RAIDZ2 成本高:** 全量部署冗余资源浪费
3. **硬件性能瓶颈:** 联想 RS160 + E3-1230 V6 + DDR4 成本高
4. **带宽压力:** 对外镜像过多导致带宽 IO 开销过大
5. **单盘风险:** 部分仓库使用单盘机械盘无冗余

第二部分: 业界参考框架 (基于搜索结果)

Slide 3: 存储分层业界实践

引用来源: 基于存储分层专利及行业公开信息

层级	业界通用定位	典型厂商实践
T0/NVMe	Hot 数据, 小容量高速 SSD	AWS S3 标准、Oracle ZFS 缓存设备
T1/SATA SSD	Warm 数据, 中容量 SSD	AWS S3 标准 -IA、又拍云热存储
T2/T3 机械盘	Cool/Cold 数据, 低成本存储	AWS Glacier 等价层
冰川 / 磁带	归档数据, 离线存储	AWS Glacier Deep Archive

Slide 4: FMA vs 业界方案对比

对比维度	FMA 实际方案	业界参考框架	事实差异
热层	ZFS 内存 ARC + NVMe	NVMe SSD	FMA 增加内存缓存层
温层	SATA SSD	SATA SSD	与又拍云等实践一致
冷层	7200 转 SAS/SATA 机械盘	7200 转垂直 / 叠瓦盘	硬件选型相同
备份层	磁带 (每两月)	磁带 / 云归档	介质一致, 周期自主
分层逻辑	高频数据动态复制	按更新频度自动分类	FMA 手动策略 vs 业界自动
成本考量	X79/X99 混合阵列	[专利未披露硬件平台]	FMO 更注重硬件性价比

第三部分：自身方案演进（展开版）

Slide 5: 文件系统方案演进

问题：初始方案 squashfs+overlayfs 导致 inode 耗尽

方案：改用底层 ZFS 阵列直接开 zstd3 压缩

事实结果：实现同等压缩率, 零 inode 管理问题

左侧：初始方案（事实）

Plain Text

- 1 应用场景：RevyOS仓库（大量硬链接）
- 2 技术栈：squashfs（只读层）+ overlayfs（读写层）
- 3 空间节省：1.2TB → 850GB（节约400G）
- 4 触发故障：同步更新时，upperdir 3小时内inode耗尽100%
- 5 故障现象：df -i显示100%占用，服务中断

右侧：最终方案（事实）

Plain Text

- 1 替换技术：ZFS文件系统 + zstd-3压缩
- 2 压缩率：与squashfs同等水平（47%）
- 3 inode管理：ZFS动态分配，无耗尽风险
- 4 实施结果：零维护成本，服务稳定运行

Slide 6: 阵列与同步演进

问题：RAIDZ2全量部署成本高 + 同步工具混乱

方案：混合阵列（高频RAIDZ2，低频单盘）+仅保留rsync

事实结果：节省冗余资源，工具单一化

上部：阵列策略演进（事实）

Plain Text

- 1 早期方案：所有仓库统一RAIDZ2（可两块盘down）
- 2 发现问题：低频仓库占用双倍冗余存储
- 3 变更策略：
- 4 └ 高频/难同步仓库：保留RAIDZ2（如RevyOS）
- 5 └ 低频/有成熟镜像仓库：单盘存储（如Ubuntu旧版本）
- 6 决策收益：节省硬件采购成本

下部：同步工具演进（事实）

Plain Text

- 1 早期工具链: rsync + wget并行
- 2 现况: 仅采用rsync从上游同步
- 3 砍掉工具: wget同步方式 (已移除)
- 4 决策依据: rsync增量同步更稳定, 工具单一化降低维护成本

Slide 7: 存储分级演进

问题: 7200 转机械盘性能瓶颈

方案: 构建四级冷热融合架构 + 磁带备份

事实结果: 已在生产环境实施

存储分层架构图 (事实):

Plain Text

```
1 |          L1: ZFS内存ARC (热数据)          |
2 |          作用: 最高频访问的元数据          |
3 |
4 |
5 |          ↓
6 |          L2: NVMe SSD (L2ARC)          |
7 |          作用: 热数据缓存, 加速读取          |
8 |
9 |
10 |          ↓
11 |          L3: SATA SSD (高频复制)          |
12 |          作用: 人工复制的常用仓库          |
13 |
14 |
15 |          ↓
16 |          L4: 7200转SAS/SATA机械盘 (主力存储)          |
17 |          作用: 所有镜像的持久化存储          |
18 |
19 |
20 |          ↓
21 |          L5: 磁带 (每两月备份)          |
22 |          作用: 变更数据离线归档          |
23 |
24 |
```

层级说明:

- **L1-L2:** ZFS 自动管理的内存与 NVMe 缓存层
- **L3:** 人工干预层, 高频仓库主动复制到 SATA SSD
- **L4:** 主力存储层, RAIDZ2 与单盘混合部署
- **L5:** 离线备份层, 磁带每两月备份变更

Slide 8: 硬件与网络演进

问题: 联想 RS160 性能拉跨, DDR4 昂贵

方案: X79/X99 平台 + CloudFlare 双出口 + 内外镜像差异化

事实结果：降低 DDR4 成本，节省带宽 IO 开销

左侧：硬件变迁（事实）

Plain Text

- 1 早期平台：联想RS160服务器
- 2 处理器：E3-1230 V6
- 3 内存：DDR4（价格昂贵）
- 4 痛点：性能拉跨 + 扩展性差
- 5
- 6 当前平台：X79和X99
- 7 内存：DDR3（性价比高）
- 8 优势：PCIe通道充足，支持多NVMe直通
- 9 结果：成本降低，性能提升

右侧：网络优化（事实）

Plain Text

- 1 对外网络：
- 2 - CDN：CloudFlare
- 3 - 负载均衡：CloudFlare自带
- 4 - 双出口：CERNET + 电信
- 5 - 镜像数量：少于对内（节省带宽IO）
- 6
- 7 对内网络：
- 8 - 负载均衡：自建LB
- 9 - 出口：多台机器
- 10 - 镜像数量：全量
- 11 - 目的：满足内部高速访问需求

Slide 9: 容灾机制演进

问题：单盘机械盘无冗余风险

方案：核心 RAIDZ2 + 磁带备份 + 多源重定向

事实结果：三级容灾保障

三层容灾架构：

第一层：热备（事实）

- **对象：**高频使用或难以同步的仓库
- **方案：**保留 RAIDZ2 阵列（可两块盘 down）
- **保障：**核心业务零中断

第二层：冷备（事实）

- **对象：**所有仓库的变更数据
- **方案：**磁带每两个月备份一次
- **恢复时效：**按需恢复，非实时

第三层：应急重定向（事实）

- **触发条件：**单盘机械盘故障
 - **备用源：**USTC、TUNA、Aliyun（国内成熟镜像源）
 - **切换逻辑：**自动检测，及时重定向
 - **用户感知：**无感知切换
-

Slide 10: 掉盘事件处理机制（基于事实）

场景：单盘存储仓库故障处理（事实时间线）

Plain Text

1 时间线：单盘机械盘故障处理
2
3 T+0分钟 监控系统告警：/dev/sdX SMART错误
4 ↓
5 T+1分钟 自动检测：仓库xxx同步失败，挂载点只读
6 ↓
7 T+2分钟 触发重定向：Nginx配置自动切换
8 - 原始URL：pkg.ftirmedia.org/xxx
9 - 重定向至：mirrors.ustc.edu.cn/xxx
10 ↓
11 T+5分钟 用户恢复访问：对外服务无感知中断
12 ↓
13 T+47分钟 应急支持工程师介入：
14 - 评估磁盘损坏程度
15 - 决定更换单盘或从tuna重启初始同步
16 ↓
17 T+4小时 物理更换硬盘
18 ↓
19 T+4小时 从tuna重启初始同步
20 - 注：磁带备份频率为每两月一次
21 ↓
22 T+24小时 仓库重新上线，关闭重定向

关键决策点（事实）：

- **重定向目标：** mirrors.ustc.edu.cn (USTC 镜像源)
- **恢复方式：** 从tuna重启初始同步（重新拉取数据，非磁带恢复）
- **工程师响应：** 应急支持工程师47分钟介入评估
- **总恢复时间：** 24小时完成全链路恢复

Slide 11: 经验验证总览

维度	事实数据
操作系统	Debian 12
文件系统	ZFS zstd3 (解决 inode 耗尽)
存储分级	5 层冷热融合 (ARC/NVMe/SATA/7200 转机械盘 / 磁带)
阵列策略	RAIDZ2 与单盘混合 (按使用频率区分)
同步工具	仅 rsync (已砍 wget)
硬件平台	联想 RS160 → X79/X99
负载均衡	对外 CloudFlare (CERNET+ 电信), 对内多机 LB
带宽策略	对外镜像少于对内
容灾机制	单盘 down 时重定向至 USTC/TUNA/Aliyun

Slide 12: 致谢页 (事实)

- 感谢 USTC/TUNA/Aliyun 等镜像源支持
 - 感谢 FMA 开源镜像站团队成员
 - 感谢清华大学天空工场社团技术支持
 - 感谢 Avrova Donz, Robin Lu, Akaere, DHC 赞助部分服务器
-