

PR #34563 完整报告

sgl-project/sglang

[diffusion] Optimize bit-exact H3 reference video ingress

合并时间: 2026-08-12 20:02

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34563>

执行摘要

- 一句话: H3 参考视频按主机单次解码并共享映射, 存储降 87.5%
- 推荐动作: 值得精读。重点关注 `_decode_reference_video_shared` 中“两轮 collective 保证决策一致”的设计: 第一轮广播 decode 状态与失败, 第二轮广播 mapping 状态与失败, 任何异常都整体回退而不是让某个 rank 单独失败; 这是多 rank 共享内存类优化中容易踩坑的地方。其次关注 text/visual 两个 stage 对 MINIMAX_H3_PREPARED_REFERENCE_VIDEO_EXTRA_KEY 生命周期的 finally 清理, 以及 `_MINIMAX_H3_SINGLE_RANK_TEXT_ENCODE_EXTRA_KEY` 在 DP 广播路径上禁用共享的细节。

功能与动机

PR body 明确指出: "Reference-video preprocessing previously ran the same CPU FFmpeg graph independently on every rank. A five-second 1344x768 reference therefore duplicated hundreds of MiB of transformed RGB pages per worker and repeated the same decode work." 即 CPU 侧的解码与内存占用在多 rank 场景被线性放大, 需要将解码结果在主机内共享, 同时保持既有的 24 FPS、Lanczos 缩放、RGB24 变换与 bit-exact 输出契约不变。

实现拆解

1. 解码入口重构: `minimax_h3_decode_reference_video_frames` 不再固定 `pipe:1` + `subprocess.run(capture_output=True)`, 新增 `share_across_replicas` 参数, 分别路由到 `_decode_reference_video_local` 或 `_decode_reference_video_shared`。ffmpeg 滤镜链 (`fps`、`lanczos`、`setsar=1`、`rgb24`) 完全不变, 保证位精确输出。
2. 本地解码优化: `_decode_reference_video_local` 在 Linux 上优先用 `os.memfd_create` 创建匿名文件描述符, 让 ffmpeg 通过 `pipe:<fd>` 直写, 再经 `_write_reference_video_to_fd` 用 `lseek` 获取实际写入字节数, `mmap(ACCESS_WRITE)` 映射为 numpy 数组; 这避免了 `communicate()` 对数百 MiB stdout 的 chunk 聚合与 bytes join。memfd 不可用 (如容器 seccomp 禁用) 时回退到旧的 `pipe:1` 路径。
3. 跨 replica 共享解码: `_decode_reference_video_shared` 在 `world_size > 1` 且 Linux 且 `/proc/self/fd` 可用时启用。先经 `_all_gather_world_objects` 收集各 rank 主机名, `_reference_video_host_leader` (带 `lru_cache`) 确定每台主机的 leader; leader 用 memfd 解码并发布 `/proc/<pid>/fd/<fd>` 路径。随后所有 rank (含 leader) 打开该路径并

以 `mmap(ACCESS_COPY)` 映射同一份物理页。整个流程分两轮 `collective`：第一轮广播 `decode` 状态与错误，第二轮广播 `mapping` 状态，任何主机失败或任何 `rank` 映射失败都会全体抛错或全体回退 `local`，避免 `collective` 分叉。

4. 调用方契约与生命周期：`text_encoding.py::_encode_ref2va` 在 `replica_world > 1` 且非单 `rank` 文本编码时启用共享，并通过 `_MINIMAX_H3_SINGLE_RANK_TEXT_ENCODE_EXTRA_KEY` 标记避免在单 `rank` 编码路径上无谓开启共享；`visual_encoding.py::_encode_reference_video` 仅在 `video_vae.parallel_tiling` 为真时共享。两个 `stage` 在成功或异常路径都会 `pop MINIMAX_H3_PREPARED_REFERENCE_VIDEO_EXTRA_KEY` 释放大映射。
5. 测试配套：`test_minimax_h3_media.py` 新增 `test_video_transform_can_share_one_host_decode`、`test_shared_video_transform_falls_back_when_proc_fd_is_blocked`、`test_shared_video_transform_propagates_any_host_decode_failure` 三个单测，分别覆盖共享解码、`/proc` 被阻断时回退、跨主机解码失败传播，并复用 `FakeGroup` + `monkeypatch` 验证两次 `all_gather_object` 的执行次数。

关键文件：

- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/model_specific_stages/minimax_h3/reference_encoding.py`（模块 媒体解码；类别 `source`；类型 `data-contract`；符号 `_decode_reference_video_local`, `_decode_reference_video_shared`, `_write_reference_video_to_fd`, `_all_gather_world_objects`）：核心实现文件：新增 `memfd` + `mmap` 本地解码路径、跨 `replica` 共享解码路径，以及两轮 `all_gather` 保证集体决策一致；同时为 `minimax_h3_prepared_reference_videos` 增加 `share_across_replicas` 契约。
- `python/sglang/multimodal_gen/test/unit/test_minimax_h3_media.py`（模块 媒体测试；类别 `test`；类型 `test-coverage`；符号 `run`, `test_video_transform_can_share_one_host_decode`, `FakeGroup`, `test_shared_video_transform_falls_back_when_proc_fd_is_blocked`）：测试配套：覆盖共享解码、`/proc` 被阻断时回退、跨主机失败传播三个关键场景，并验证两次 `all_gather` 的执行次数，是保证集体操作一致性的重要防线。
- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/model_specific_stages/minimax_h3/stages/text_encoding.py`（模块 文本编码；类别 `source`；类型 `data-contract`；符号 `MiniMaxH3TextEncodingStage.forward`, `MiniMaxH3TextEncodingStage.run_grouped_requests`, `MiniMaxH3TextEncodingStage._encode_ref2va`）：调用方契约变更：在文本编码阶段根据 `replica world size` 与单 `rank` 编码标记决定是否开启跨 `replica` 共享，并在异常与单 `rank` 路径清理 `prepared video extra key`。
- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/model_specific_stages/minimax_h3/stages/visual_encoding.py`（模块 视觉编码；类别 `source`；类型 `data-contract`；符号 `MiniMaxH3VisualEncodingStage.forward`, `MiniMaxH3VisualEncodingStage._encode_reference_video`）：调用方契约变更：视觉编码阶段仅在 `video VAE` 并行 `tiling` 时启用共享解码，并在 `forward` 的 `finally` 中释放大映射，防止后续 `stage` 长时间持有数百 `MiB` 的请求本地视图。

关键符号：`minimax_h3_decode_reference_video_frames`,
`_decode_reference_video_local`, `_decode_reference_video_shared`,

```
_write_reference_video_to_fd, _all_gather_world_objects,  
_reference_video_host_leader,minimax_h3_prepared_reference_videos,  
MiniMaxH3TextEncodingStage._encode_ref2va,  
MiniMaxH3VisualEncodingStage._encode_reference_video
```

关键源码片段

[python/sglang/multimodal_gen/test/unit/test_minimax_h3_media.py](#)

测试配套：覆盖共享解码、/proc 被阻断时回退、跨主机失败传播三个关键场景，并验证两次 all_gather 的执行次数，是保证集体操作一致性的重要防线。

```
@pytest.mark.skipif(not sys.platform.startswith("linux"), reason="requires Linux memfd")  
def test_shared_video_transform_propagates_any_host_decode_failure(monkeypatch):  
    """任一 host 的 leader 解码失败时，所有 rank 必须同步抛错、不再进入映射 collective"""  
    class FakeGroup:  
        world_size = 4  
        rank_in_group = 0  
        cpu_group = object()  
  
    gather_index = 0  
  
    def all_gather_object(outputs, value, **_kwargs):  
        nonlocal gather_index  
        if gather_index == 0:  
            # 第一轮：主机名分布为 host-a x2 + host-b x2  
            outputs[:] = ["host-a", "host-a", "host-b", "host-b"]  
        else:  
            # 第二轮：host-b 的 leader 携带解码失败信息  
            outputs[:] = [  
                value,  
                None,  
                (None, 0, "CalledProcessError: remote decode failed"),  
                None,  
            ]  
            gather_index += 1  
  
    monkeypatch.setattr(reference_encoding, "get_world_group", FakeGroup)  
    monkeypatch.setattr(torch.distributed, "all_gather_object", all_gather_object)  
    monkeypatch.setattr(  
        reference_encoding,  
        "_write_reference_video_to_fd",  
        lambda _command, _fd: 1,  
    )  
    reference_encoding._reference_video_host_leader.cache_clear()  
    try:  
        with pytest.raises(RuntimeError, match="remote decode failed"):  
            reference_encoding._decode_reference_video_shared(["ffmpeg"])  
    finally:
```

```
reference_encoding._reference_video_host_leader.cache_clear()
```

```
# 失败在共享状态交换后立即解决，任何 rank 都不会进入被跳过的映射 collective  
assert gather_index == 2
```

评论区精华

本 PR 无 Review 评论 (comments_count = 0、review_comments_count = 0)，由作者直接合入。从实现注释与 PR body 可以提炼出关键设计决策：任一主机解码失败必须在第一轮状态交换后立即传播，使所有 rank 同时退出，绝不进入后续 mapping collective；`/proc fd` 遍历可能被 `hidepid` 或容器策略拒绝，此时全体回退到 rank-local 解码，保证优化永远不改变原有请求的成功与否或 RGB 字节 (bit-exact 契约)。这些决策通过三个针对性单测固化，测试还断言失败场景 `gather_index == 2`，即不会多执行一次集体通信。

- 暂无高价值评论线程

风险与影响

- 风险：
 - 集体通信一致性：`_decode_reference_video_shared` 内部有两次 `all_gather_object`，要求所有 rank 对 `sys.platform`、`/proc/self/fd` 存在性、`world_size` 的判定完全一致；若环境差异导致部分 rank 进入共享路径、部分进入 local 路径，会发生集体操作挂起。目前条件均为各 rank 应当一致的静态环境判断，风险可控但值得在异构容器环境中验证。
 - 平台与容器兼容性：依赖 `memfd_create`、`/proc/<pid>/fd` 跨进程打开、`hidepid/` 容器 `seccomp` 策略。代码对每种失败都提供了回退，但回退本身依赖第一次 collective 成功执行。
 - 映射生命周期：mapping 对象存放在 `batch.extra`，由 `text/visual` 两个 stage 的 `finally` 或异常分支 `pop` 释放；`leader` 的 `fd` 在多个异常出口显式 `os.close`。若未来新增第三个 RGB 消费方，可能提前释放或重复映射。
 - 内存语义：非 `leader` 使用 `ACCESS_COPY` 写时复制映射，若消费方原地修改 frames 不会污染共享页；`leader` 走 `ACCESS_WRITE` 则反之，测试中仅验证了可写性，未验证跨 rank 修改隔离。
 - 性能回退：共享路径多出两轮 collective，对小视频或单卡场景反而可能更慢；代码通过 `world_size <= 1` 与 `parallel_tiling` 条件规避了无谓开销。
- 影响：
 - 用户侧：MiniMax H3 ref2va 多 GPU 部署的参考视频预处理内存占用显著下降（单条 5 秒 1344×768 参考视频解码存储减少约 2.60 GB，峰值 RSS 减半），降低 OOM 风险；多机多卡下收益更明显，且输出保持 bit-exact。
 - 系统侧：减少 CPU 重复解码与 Python 侧大缓冲拷贝，释放内存带宽；`mmap` 共享物理页使同一主机的多个 worker 进程只保留一份 RGB 数据。
 - 团队侧：确立了“主机内单次解码 + 跨进程映射 + 集体回退”的模式，为 `diffusion` 其他视频链路（如 SANA、Cosmos）的 `ingress` 优化提供了可复用范式；同时新增的 `extra key` 生命周期约定需要后续开发者在新增多媒体 stage 时注意。

- 风险标记：多 rank 集体通信一致性，memfd 与 /proc 平台依赖，映射生命周期与 fd 泄漏，共享路径回退分支，bit-exact 契约回归风险

关联脉络

- PR #34564 [diffusion] Stream and parallelize bit-exact video output saves: 同为 diffusion bit-exact 视频 I/O 的流式与并行优化，一个优化输出保存、一个优化输入解码，可对照理解 bit-exact 契约在 SGLang Diffusion 中的处理方式。
- PR #34359 [Diffusion] Support native and PEFT MiniMax H3 LoRAs: 该 PR 同样改动 MiniMax H3 reference_encoding 链路与 media 相关测试，属于 H3 ref2va 功能线的延续。
- PR #34412 [Diffusion] Improve bit-exact fusion fallback diagnostics: 同属 bit-exact 主题，关注融合回退行为与诊断，与本 PR 的 fallback 设计有共同的方法论。