

PR #31217 完整报告

sgl-project/sglang

[Disagg][StagingBuffer][1/2] Robustness and failure handling

合并时间: 2026-07-24 17:22

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/31217>

执行摘要

- 一句话: 修复 PD staging buffer 泄漏与注册竞争等健壮性问题
- 推荐动作: 此 PR 值得精读, 尤其 `release_room` 的设计体现了失败路径中资源清理的严谨思考, 权衡了同步开销与数据安全。注册顺序调整解决了一个微妙的推拉竞争条件。建议关注第二部分 [2/2] RadixCache 的后续演进。

功能与动机

在构建 RadixCache 支持 ([2/2]) 过程中, 发现了 staging buffer 路径的多个健壮性问题, 每个问题均独立且可能导致永久性阻塞或资源泄漏。本 PR 将这些修复独立拆分以便审查。

实现拆解

1. 新增 `release_room` 释放逻辑: 在 `staging_handler.py` 的 `unregister_decode_req` 中调用 `release_room`, 同步 scatter stream 后释放未完成分配的 staging 槽位, 避免 watermark 卡死。
2. 调整注册顺序: 将 `register_decode_req` 调用从 `decode.py` 的 `extend` 移至 `pop_preallocated`, 确保在 `send_metadata` 之前完成注册, 消除 STAGING_REQ 丢弃窗口。
3. 失败显式传播: 删除了 `mooncake/conn.py` 和 `nixl/conn.py` 中静默忽略 `CHUNK_READY` 发送失败的 `try-except`, 改为直接抛出异常; 同时 `_do_staging_transfer` 在 staging 无法容纳时返回 -1 而非回退, 避免泄漏。
4. 启动时配置验证: 在 `prefill.py` 的 `__init__` 中添加对 `chunked_prefill_size`、`pp_size`、`enable_prefill_context_parallel` 的兼容性检查, 不满足时直接报错。
5. 配套测试与文档更新: 修改了两处测试文件以调整参数, 删除文档中已废弃的环境变量说明。

关键文件:

- `python/sglang/srt/disaggregation/common/staging_handler.py` (模块 存根处理; 类别 source; 类型 entrypoint; 符号 `release_room`, `init_staging_buffers`): 核心修改文件, 新增 `release_room` 方法用于失败时释放未完成的 staging 分配, 调整注册顺序和添加配置验证
- `python/sglang/srt/disaggregation/mooncake/conn.py` (模块 Mooncake 后端; 类别 source; 类型 core-logic; 符号 `_send_chunk_ready`, `_do_staging_transfer`, `_init_staging_buffers`): Mooncake 传输后端, 修改 `_send_chunk_ready` 移除静默异常捕

获, `_do_staging_transfer` 返回 -1 而非回退, 并传入 `chunked_prefill_size`

- `python/sglang/srt/disaggregation/nixl/conn.py` (模块 NIXL 后端; 类别 source; 类型 dependency-wiring; 符号 `transfer_worker`, `_do_staging_transfer`, `_init_staging_buffers`): NIXL 传输后端, 类似 mooncake 调整, 导入 `STAGING_WATERMARK_WAIT_S`, 修改 `transfer_worker` 和 `_do_staging_transfer` 以显式失败
- `python/sglang/srt/disaggregation/prefill.py` (模块 预填充; 类别 source; 类型 core-logic; 符号 `init`): 启动时验证 staging 兼容配置, 确保 `chunked_prefill_size` 页对齐、不支持 `pp_size>1` 和 context parallelism
- `python/sglang/srt/disaggregation/decode.py` (模块 解码调度; 类别 source; 类型 core-logic; 符号 `pop_preallocated`, `extend`): 调整 `register_decode_req` 调用位置, 在 `pop_preallocated` 中优先于 `send_metadata` 注册, 避免 `STAGING_REQ` 竞争; 清理 `extend` 中的重复注册

关键符号: `release_room`, `init_staging_buffers`, `_send_chunk_ready`, `_do_staging_transfer`, `register_decode_req`, `unregister_decode_req`, `transfer_worker`

关键源码片段

`python/sglang/srt/disaggregation/prefill.py`

启动时验证 staging 兼容配置, 确保 `chunked_prefill_size` 页对齐、不支持 `pp_size>1` 和 context parallelism

```
# 在 PrefillRequest.__init__ 中, 当启用 SGLANG_DISAGG_STAGING_BUFFER 时,  
# 验证 staging 所需的服务端参数兼容性, 不满足则立即报错。
```

```
if envs.SGLANG_DISAGG_STAGING_BUFFER.get():
```

```
    if self.is_mla_backend:
```

```
        raise RuntimeError(
```

```
            "SGLANG_DISAGG_STAGING_BUFFER 仅为非 MLA 模型设计"
```

```
            " (例如 GQA、MHA) 。MLA 模型不应设置此标志。"
```

```
        )
```

```
    server_args = self.scheduler.server_args
```

```
    page_size = self.scheduler.token_to_kv_pool_allocator.page_size
```

```
    # chunked_prefill_size 是 staging 网格分块的基础: 必须
```

```
    # 为正整数且是 page_size 的整数倍, 否则无法划分固定网格。
```

```
    cps = server_args.chunked_prefill_size or 8192
```

```
    if cps <= 0 or cps % page_size != 0:
```

```
        raise RuntimeError(
```

```
            f"SGLANG_DISAGG_STAGING_BUFFER 要求 chunked_prefill_size "
```

```
            f"为正整数且是 page_size ({page_size}) 的整数倍; "
```

```
            f"当前值: {server_args.chunked_prefill_size}。"
```

```
        )
```

```
    # Staging 写入方没有 pp (流水线并行) 维度, 不支持 pp_size > 1。
```

```
    if self.pp_size > 1:
```

```
        raise RuntimeError(
```

```
            "SGLANG_DISAGG_STAGING_BUFFER 不支持 pp_size > 1。"
```

```
        )
```

```
# 上下文并行会按 rank 重写 index_slice, 破坏 chunk grid。
if server_args.enable_prefill_context_parallel:
    raise RuntimeError(
        "SGLANG_DISAGG_STAGING_BUFFER 不支持预填充上下文并行。"
    )
```

评论区精华

- `release_room` 同步必要性: YAMY1234 解释同步 `scatter stream` 是因失败路径已释放 KV-pool 页面, 后续请求可能复用, 必须同步防止数据竞争。结论: 采用 `per-event synchronize`, 仅阻塞调用线程。
- 是否 `kill` 传输线程: ShangmingCai 建议不应 `kill` 传输线程, 因同一 `prefill` 可能服务其他 `decode` 实例。YAMY1234 接受并改为仅失败当前 `room` 并返回 `-1`。
- 运行时错误 vs 初始化检查: ShangmingCai 询问 `nixl` 中 `handle is None` 错误能否通过初始化配置避免。YAMY1234 指出 `decode` 侧 `staging` 大小在 `bootstrap` 时才可知, 无法静态保证。
- `chunked_prefill_size` 验证: ShangmingCai 询问 `--chunked-prefill-size -1` 情况, YAMY1234 添加了启动时 `guard` 禁止该配置与 `staging` 同时使用。
 - `release_room` 中同步 `scatter stream` 的必要性 (`correctness`): 确认同步是必要的, 采用 `per-event synchronize` 而非全设备同步, 仅阻塞调用线程。
 - `staging` 失败是否应 `kill` 传输线程 (`design`): 改为 `warning` 并返回 `-1`, 只失败当前 `room`。
 - 运行时错误 vs 初始化检查 (`question`): 保留运行时检查, 因为动态协商无法静态验证。
 - `chunked_prefill_size` 配置验证 (`correctness`): 添加了启动时验证, `chunked_prefill_size` 必须为正整数且页对齐。

风险与影响

- 风险:
 - `release_room` 调用 `stream.synchronize()` 可能阻塞主线程, 影响延迟, 但仅在失败路径执行。
 - 注册顺序调整可能引入新的竞争条件, 若 `pop_preallocated` 在其他场景提前调用可能导致未注册 (但当前仅一处调用, 风险可控)。
 - 启动时配置验证增加约束, 可能影响已使用非兼容配置的用户部署 (但限制合理)。
 - 删除文档中的环境变量可能使用户困惑, 但变量已被取代。
- 影响:
 - 用户影响: PD 传输在失败 / 中止场景下更加稳健, 不再有永久阻塞或泄漏, 提升系统可靠性。
 - 系统影响: 仅在失败路径增加少量同步开销, 正常路径性能不变。重试机制避免了忙等待, 减少 CPU 浪费。
 - 团队影响: 为后续 `RadixCache` 支持奠定基础, 代码结构更清晰, 失败路径易于推理。
 - 风险标记: 核心路径变更, 并发安全, 同步开销

关联脉络

- 暂无明显关联 PR