

PR #28086 完整报告

sgl-project/sglang

Abort during chunked prefill + PD peer-liveness abort

合并时间: 2026-06-18 14:13

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28086>

执行摘要

- 一句话: 实现分块预填充中止与 PD 对端存活检测
- 推荐动作: 值得精读, 特别是 `process_pending_chunked_abort` 的安全中止模式 (延迟处理 + 多个调度点) 和 `resolve_waiting_queue_bootstrap` 的对端检测集成方式。测试代码也提供了良好的端到端验证范例。建议熟悉 scheduler 和 PD 模块的团队成员优先 Review。

功能与动机

PR body 指出: 'Two abort improvements for the PD / chunked-prefill path.' 在 chunked prefill 场景下, 原有中止请求只在分块之间生效, 分块处理中无法立即中止。PD 模式下对端失效后没有自动中止机制, 可能导致请求挂起。该 PR 通过记录待中止的 chunked request 并在调度器安全点清理, 以及添加对端存活轮询, 解决了这些问题。

实现拆解

1. 安全中止标记与延迟清理: 在 `scheduler.py` 的 `init_chunked_prefill` 中新增 `_pending_chunked_abort_req` 属性; `abort_request` 仅将目标请求赋值给此标记, 避免在迭代中途直接销毁。新增 `process_pending_chunked_abort` 方法, 在每个调度步 `get_next_batch_to_run` 开头调用。
2. 中止逻辑: `process_pending_chunked_abort` 判断待中止请求是否为当前分块 (`chunked_req`)。若是, 则调用 `prepare_abort` 标记中止、释放 KV 缓存 (含 `disagg sender/metadata buffer`)、清空 `chunked_req` 并通知 `tokenizer`; 若不是, 则在请求完结后清除标记。在 `disagg prefill` 模式下还处理 `maybe_release_metadata_buffer` 和 `release_kv_cache`。
3. 对端存活检测: 在 `disaggregation/prefill.py` 中新增 `resolve_waiting_queue_bootstrap`, 在 `get_next_disagg_prefill_batch_to_run` 中调用。该方法遍历等待队列中未中止的请求, 通过 `poll_and_all_reduce_attn_cp_tp_group` 检测 `disagg_kv_sender` 状态。若收到 `KVPoll.Failed`, 则调用 `handle_bootstrap_failure` 中止请求并从等待队列移除; 若 `KVPoll.WaitingForInput` 且请求已乐观完成 `bootstrap`, 则调用 `finalize_bootstrap`。
4. 入口集成: 修改 `get_next_batch_to_run` (统一模式) 和 `get_next_disagg_prefill_batch_to_run` (PD 模式) 的调度步骤, 分别插入 `process_pending_chunked_abort` 和 `resolve_waiting_queue_bootstrap`。

5. 配套调整：在 `batch_result_processor.py` 中微调结果处理以跳过已中止的 chunk；更新单元测试 mock (`test_scheduler_chunked_req_gate.py`) 以初始化 `_pending_chunked_abort_req`。

关键文件：

- `python/sglang/srt/managers/scheduler.py` (模块 调度器；类别 source；类型 core-logic；符号 `process_pending_chunked_abort`)：核心调度器，新增 `process_pending_chunked_abort` 方法实现 chunked prefill 中止安全处理，并在 `get_next_batch_to_run` 入口调用。
- `python/sglang/srt/disaggregation/prefill.py` (模块 预填充管理；类别 source；类型 core-logic；符号 `resolve_waiting_queue_bootstrap`)：预填充管理，新增 `resolve_waiting_queue_bootstrap` 方法检测对端存活并处理失效，集成到 `get_next_disagg_prefill_batch_to_run`。
- `python/sglang/test/manual/disaggregation/test_disaggregation_peer_liveness_abort.py` (模块 对端存活测试；类别 test；类型 test-coverage；符号 `_body_text`, `_decode_response`, `_finish_reason`, `_is_abort_result`)：新增手动测试，验证 PD 对端失效后自动中止并恢复，覆盖对端存活检测核心场景。
- `python/sglang/test/manual/disaggregation/test_chunked_prefill_abort.py` (模块 分块中止测试；类别 test；类型 test-coverage；符号 `_decode_response`, `_is_abort_result`, `TestChunkedPrefillAbortE2E`, `test_abort_mid_chunked_prefill_by_rid`)：新增手动测试，验证统一模式下 chunked prefill 中止功能。
- `test/registered/disaggregation/test_disaggregation_basic.py` (模块 PT 测试套件；类别 test；类型 test-coverage；符号 `_decode_response`, `_is_abort_result`, `TestDisaggChunkedPrefillAbort`, `_post_abort`)：注册 CI 的测试文件，新增 `TestDisaggChunkedPrefillAbort` 类，将 chunked prefill 中止测试纳入持续集成。

关键符号：`process_pending_chunked_abort`, `resolve_waiting_queue_bootstrap`

评论区精华

- 代码风格：merrymercy 在 review 中指出“try to remove all `getattr` and `hasattr`”，强调应避免 `getattr`，保持类型安全。作者 cctry 随即移除了相关 `getattr` 调用。
- 正确性补充：ShangmingCai 在 `scheduler.py` 的 `process_pending_chunked_abort` 中建议添加 `req.time_stats.trace_ctx.abort` 调用以保持与其它中止路径一致。作者采纳并添加。
- CI 测试注册：ShangmingCai 在 approve 评论中建议“Should we pick and register one of the tests in `test/registered/disaggregation/test_disaggregation_basic.py`?”。作者随后将 `TestDisaggChunkedPrefillAbort` 类加入该注册测试文件，并调整了 CI 预估时间。
 - 使用 `getattr` 的代码风格 (style)：作者移除了 `getattr` 调用，改用直接属性访问。
 - 缺少 `trace abort` 调用 (correctness)：在 `process_pending_chunked_abort` 中添加了 `trace_ctx.abort` 调用，与其他中止路径一致。
 - 将测试注册到 CI (testing)：作者将 `TestDisaggChunkedPrefillAbort` 类添加到 `test_disaggregation_basic.py` 并注册 CI。

风险与影响

- 风险：
 - 核心路径变更：scheduler.py 是调度器核心，新增的 process_pending_chunked_abort 在每个调度步调用，可能引入回归，需关注请求泄漏或死锁。
 - PD 模式网络依赖：resolve_waiting_queue_bootstrap 中引入的 poll_and_all_reduce_attn_cp_tp_group 网络轮询可能增加 PD 模式下请求入队延迟，若网络抖动可能误判对端失败。
 - KV 缓存释放安全性：中止路径中的 release_kv_cache 和 maybe_release_metadata_buffer 必须与主路径一致，避免双重释放或泄漏。
 - 测试时长：新增的 CI 测试（预估时间从 560 秒提升到 700 秒）可能增加 CI 流水线耗时。
- 影响：
 - 用户影响：chunked prefill 场景下调用 abort_request 可立即停止分块处理，PD 模式下对端失效的请求自动中止，无需手动干预，提升用户体验。
 - 系统影响：调度器增加了 _pending_chunked_abort_req 属性和两步检查，引入的判断开销极低；PD 模式下每步调度增加一次全量请求的轮询，对规模化部署可能产生轻微延迟。
 - 团队影响：新增的手动测试和 CI 测试为后续类似功能提供了代码模板，降低测试编写门槛。
 - 风险标记：核心调度路径变更，PD 模式依赖网络，新增 CI 测试时长增加

关联脉络

- 暂无明显关联 PR