

PR #31869 完整报告

sgl-project/sglang

[PD+PP] Honor PP consensus for bootstrap and prealloc

合并时间: 2026-07-30 01:19

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/31869>

执行摘要

- 一句话: 修复 PD+PP 中 bootstrap 和 prealloc 的共识竞态问题
- 推荐动作: 此 PR 设计清晰, 值得精读: 通过“共识映射”避免二次同步的策略可推广至其他多 rank 协调场景; 处理局部失败的设计考虑周全。关注 `poll_and_all_reduce_pp` 函数和 `pop_bootstrapped` 中的 PP/ 非 PP 分支选择。

功能与动机

在 PD 解耦部署中, Prefill bootstrap 和 Decode preallocation 已通过 all-reduce 计算 PP consensus (`global_ready` 和 `global_failed`)。但队列消费者在 consensus 后再次轮询本地 sender/receiver 状态, 导致 consensus 与队列处理间到达的 abort 可能使 PP 阶段应用不同结果而分歧。此 PR 遵循 #31030 的 review comments, 范围限于 Prefill bootstrap 和 Decode preallocation, 避免二次轮询。

实现拆解

1. 新增映射函数: 在 `python/sglang/srt/disaggregation/utils.py` 中添加 `poll_and_all_reduce_pp`, 利用传入的 `good_rids/bad_rids` 集合直接返回 poll 结果, 避免再次执行 all-reduce。
2. Prefill bootstrap 改造: 在 `python/sglang/srt/disaggregation/prefill.py` 的 `pop_bootstrapped` 中, 当 `self.pp_size > 1` 时调用新函数, 并对未覆盖的请求 (consensus 中不存在) 执行本地 `poll_and_all_reduce_attn_cp_tp_group` 仅捕获 Failed 状态, 防止资源泄漏。
3. Decode prealloc 改造: 在 `python/sglang/srt/disaggregation/decode.py` 的 `_update_handshake_waiters` 和 `pop_preallocated` 中同理, PP 模式下使用共识结果, 非 PP 模式保持原有本地轮询。
4. 调度器 PP 混入层适配: 在 `python/sglang/srt/managers/scheduler_pp_mixin.py` 的 `process_bootstrapped_queue` 和 `process_prealloc_queue` 中将旧参数 `rids_to_check` 替换为 `pp_good_rids` 和 `pp_bad_rids`。
5. 测试兼容: 在三个测试文件中为新增加的 `pp_size` 属性设置默认值 1, 确保非 PP 用例继续通过。

关键文件:

- python/sglang/srt/disaggregation/utils.py (模块 解耦工具; 类别 source; 类型 dependency-wiring; 符号 poll_and_all_reduce_pp) : 新增核心函数 poll_and_all_reduce_pp, 实现共识到 poll 结果的直接映射, 是本次修复的基础。
- python/sglang/srt/disaggregation/prefill.py (模块 预填充处理; 类别 source; 类型 core-logic) : 在 pop_bootstrapped 中增加 PP 分支, 使用共识结果并处理局部失败, 是 Prefill bootstrap 正确性的关键修改。
- python/sglang/srt/disaggregation/decode.py (模块 解码处理; 类别 source; 类型 core-logic) : 在 _update_handshake_waiters 和 pop_preallocated 中应用一致修改, 影响 Decode preallocation 路径。
- python/sglang/srt/managers/scheduler_pp_mixin.py (模块 调度 PP 层; 类别 source; 类型 core-logic) : 适配新接口: 将 process_bootstrapped_queue 和 process_prealloc_queue 中的旧参数替换为 pp_good_rids/pp_bad_rids。
- test/registered/unit/disaggregation/test_decode_queue_cleanup.py (模块 解码测试; 类别 test; 类型 test-coverage) : 为 DecodePreallocQueue 测试设置 pp_size = 1 以兼容新分支。
- test/registered/unit/managers/test_priority_scheduling_disaggregation.py (模块 调度测试; 类别 test; 类型 test-coverage) : 类似地设置 pp_size = 1 维持非 PP 测试覆盖率。
- test/registered/unit/mem_cache/test_decode_radix_lock_ref.py (模块 锁测试; 类别 test; 类型 test-coverage) : 同样添加 pp_size = 1 设置, 保持测试通过。

关键符号: poll_and_all_reduce_pp, pop_bootstrapped, pop_preallocated, _update_handshake_waiters, process_bootstrapped_queue, process_prealloc_queue

关键源码片段

python/sglang/srt/disaggregation/utils.py

新增核心函数poll_and_all_reduce_pp, 实现共识到poll结果的直接映射, 是本次修复的基础。

```
def poll_and_all_reduce_pp(
    rids: Iterable[str], # 所有待检查的请求 ID
    ready_poll: int, # 共识通过时返回的 poll 状态 (如 KVPoll.WaitForInput)
    pp_good_rids: Optional[List[str]] = None, # 所有 PP stage 认为 ready 的 RID 集合
    pp_bad_rids: Optional[List[str]] = None, # 所有 PP stage 认为 failed 的 RID 集合
) -> List[Optional[int]]:
    """将权威的 PP 共识映射为 poll 状态, 无需再次轮询本地状态。"""
    if pp_good_rids is None or pp_bad_rids is None:
        raise ValueError("PP consensus is required")

    # 转为 set 实现 O(1) 查找, failure 优先
    good_rids = set(pp_good_rids)
    bad_rids = set(pp_bad_rids)
    return [
        KVPoll.Failed if rid in bad_rids # 任何 stage 失败 => Failed
        else ready_poll if rid in good_rids # 所有 stage 准备好 => ready_poll
        else None # 未在共识中 => 需要本地检查
        for rid in rids
    ]
```

]

python/sglang/srt/disaggregation/prefill.py

在 `pop_bootstrapped` 中增加 PP 分支，使用共识结果并处理局部失败，是 Prefill bootstrap 正确性的关键修改。

```
def pop_bootstrapped(
    self,
    return_failed_reqs: bool = False,
    pp_good_rids: Optional[List[str]] = None,
    pp_bad_rids: Optional[List[str]] = None,
) -> List[Req] | tuple[List[Req], List[Req]]:
    """
    pop 已完成 bootstrap 的请求。
    PP 模式下使用传入的共识结果，无需再次轮询本地 sender。
    """

    bootstrapped_reqs = []
    failed_reqs = []
    indices_to_remove = set()

    if not self.queue:
        return ([], []) if return_failed_reqs else []

    if self.pp_size > 1:
        # PP 模式：使用权威共识结果
        polls = poll_and_all_reduce_pp(
            (req.rid for req in self.queue),
            KVPoll.WaitingForInput,
            pp_good_rids,
            pp_bad_rids,
        )
        uncovered = [i for i, poll in enumerate(polls) if poll is None]
        if uncovered:
            # 对未覆盖的请求做本地轮询，只捕获 Failed，防止泄漏
            local_polls = poll_and_all_reduce_attn_cp_tp_group(
                [self.queue[i].disagg_kv_sender for i in uncovered],
                self.scheduler.attn_cp_cpu_group,
                self.scheduler.attn_tp_cpu_group,
            )
            for i, local_poll in zip(uncovered, local_polls):
                if local_poll == KVPoll.Failed:
                    polls[i] = KVPoll.Failed
        else:
            # 非 PP 模式：传统本地轮询
            polls = poll_and_all_reduce_attn_cp_tp_group(
                [req.disagg_kv_sender for req in self.queue],
                self.scheduler.attn_cp_cpu_group,
                self.scheduler.attn_tp_cpu_group,
            )
```

```
for i, (req, poll) in enumerate(zip(self.queue, polls)):
    if poll is None:
        continue # 未决定, 下次再处理
    if poll == KVPoll.Failed:
        # 失败处理 ...
```

评论区精华

命名改进(ShangmingCai): “I think the naming should be improved. Not yet success, just good to check.” 最终采用 `ready_rids` 语义, 避免与 `successful_rids` 混淆 (bootstrap 仅为 ready 而非 transfer 成功)。防御性分支(ShangmingCai): “How about checking `self.pp_size > 1` first, then run into this logic block?” 作者在后续版本中添加了 `if self.pp_size > 1` 检查, PP=1 时走原始路径。未覆盖请求处理(ShangmingCai): “Local failures are terminal and must be drained even if PP consensus no longer covers the request...” 作者对 uncovered 请求增加本地轮询, 仅应用 `Failed` 状态, 避免元数据泄漏。移除简化(ShangmingCai): “`_apply_handshake_polls` here is weird.” 作者移除了该抽象, 在 `decode prealloc` 中直接应用共识结果及小助手 `_abort_handshake`。

- 函数命名与语义 (design): 采用 `ready_rids` 和 `ready_poll` 避免误导, 文件为 `poll_and_all_reduce_pp`。
- PP 分支的防御性检查 (design): 作者在 `prefill` 和 `decode` 中均添加了 `if pp_size > 1`: 分支, PP=1 走原始路径。
- 未覆盖请求的局部失败处理 (correctness): 仅对 uncovered 请求执行本地轮询, 只应用 `Failed` 状态; good 未覆盖的请求会留到下一周期。
- 移除多余抽象 (refactor): 作者移除该函数, 在 `decode prealloc` 中直接使用共识结果和 `_abort_handshake` 辅助。

风险与影响

- 风险:
 1. 局部失败及时序风险: PP 共识后、队列处理前, 某 rank 本地可能发生失败。对于共识中的 good 请求, 代码不再轮询, 若本地失败未被之前共识捕获 (极低概率), 该请求可能被错误认为良好, 但共识 all-reduce 已汇集最近状态, 风险可控。
 2. 未覆盖请求的遗漏: 若 uncovered 请求本地轮询也返回 None (既非 Failed 也非 good), 该请求会被跳过, 下个周期继续处理, 不会泄漏 (代码中 continue 但仍在队列中)。
 3. 无性能风险: 非 PP 路径完全不变, PP 路径反而减少一次 all-reduce。- 影响: 用户: 修复了 PD+PP 部署下可能导致请求永久阻塞或被错误中止的竞态条件, 提升可靠性。系统: 控制面延迟从 $\sim 50\mu s$ 降至 $\sim 0.3\mu s$ (PP 路径), 减少同步开销。团队: 代码更加简洁, 移除了冗余轮询逻辑和复杂参数 `rids_to_check`, 增强可维护性。影响范围仅限于 `PD + PP > 1` 的场景。
- 风险标记: 局部失败时序风险, 共识窗口竞态, 测试覆盖仅 base PP=1

关联脉络

- PR #31030 [PD+PP] Authoritative bootstrap queue consumer for PP consensus: 此 PR 的原始提案和设计讨论，本 PR 直接基于其 review comments 实现。
- PR #30476 WIP: PP consensus for disaggregated prefill bootstrap: 早期探索性 PR，涉及相同概念，本 PR 最终实现方案。