

PR #36351 完整报告

sgl-project/sglang

fix(disagg): snapshot affected rooms before iterating outside the lock

合并时间: 2026-08-26 03:31

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36351>

执行摘要

- 一句话: 锁外迭代前快照 affected rooms 修复竞态
- 推荐动作: 值得精读, 尤其是对 CommonKVManager 和节点故障处理机制感兴趣的工程师。
该 PR 展示了如何通过简单的快照修复隐患, 并详细分析了各后端的访问模式, 对理解锁内外数据一致性有启发。

功能与动机

PR 描述指出, `_handle_node_failure` 在 `connection_lock` 下取出房间集合, 但释放锁后才迭代。`.get()` 返回的是活集合而非副本, 安全性依赖于所有变异方的访问模式, 而 `MoriKVManager._cleanup_room_tracking` 违反了该假设, 可能在同一对象上 `discard` 导致迭代期间修改。一旦触发, 异常会逃逸心跳线程, 导致节点故障检测永久静默失效, 风险极高。尽管当前只有 Mooncake 和 Nixl 使用该线程, 但 mori 接入仅需一行, 且失效后果严重, 因此值得加固。

实现拆解

1. 定位问题: 在 `python/sglang/srt/disaggregation/common/conn.py` 的 `_handle_node_failure` 中, 原代码 `possible_affected_rooms = self.addr_to_rooms_tracker.get(failed_bootstrap_addr, [])` 在锁内获取活集合, 锁外迭代。
2. 修改方案: 将获取改为 `possible_affected_rooms = list(self.addr_to_rooms_tracker.get(failed_bootstrap_addr, []))`, 在锁内完成快照。
`list()` 对内置集合是原子的, 可防止迭代期间其他线程修改。
3. 行为保持不变: 既访问相同房间, 也照样 `pop` 跟踪条目, 无需其他改动。
4. 测试与配置: PR 明确说明不添加单元测试 (时间依赖的竞态难以确定性测试), 仅提供复现实验数据; CI 阶段触发了 `disaggregation` 相关测试并全部通过。

关键文件:

- `python/sglang/srt/disaggregation/common/conn.py` (模块 连接管理; 类别 `source`; 类型 `core-logic`; 符号 `_handle_node_failure`): 核心修改文件, 修复锁外迭代活集合的竞态问题。

关键符号: `_handle_node_failure`

关键源码片段

python/sglang/srt/disaggregation/common/conn.py

核心修改文件，修复锁外迭代活集合的竞态问题。

python/sglang/srt/disaggregation/common/conn.py (节选)

```
def _handle_node_failure(self, failed_bootstrap_addr: str):
    """处理 prefill 节点故障。"""
    with self.connection_lock:
        keys_to_remove = [
            k for k in self.connection_pool if k.startswith(failed_bootstrap_addr)
        ]
        stale_endpoints = set()
        for k in keys_to_remove:
            for info in self.connection_pool[k]:
                ip = info.get("rank_ip")
                port = info.get("rank_port")
                if ip and port:
                    na = NetworkAddress(ip, int(port))
                    stale_endpoints.add(na.to_tcp())
        for k in keys_to_remove:
            del self.connection_pool[k]
        self.prefill_info_table.pop(failed_bootstrap_addr, None)

    # 注意：这里必须在锁内生成快照，不能直接引用活集合。
    # 因为后续迭代发生在锁外，而 `Mori` 后端可能缓存该集合的引用并
    # 在无锁情况下修改它，导致迭代时 `RuntimeError`。
    possible_affected_rooms = list(
        self.addr_to_rooms_tracker.get(failed_bootstrap_addr, [])
    )
    self.addr_to_rooms_tracker.pop(failed_bootstrap_addr, None)

    for endpoint in stale_endpoints:
        CommonKVReceiver.disconnect_endpoint(endpoint)

    affected_rooms = []
    for room in possible_affected_rooms:
        if (
            room in self.request_status
            and self.check_status(room) != KVPoll.Success
        ):
            self.record_failure(
                room,
                f"Lost connection with prefill instance (bootstrap_addr: {failed_bootstrap_addr})",
            )
            self.update_status(room, KVPoll.Failed)
            affected_rooms.append(room)

    logger.error(
        f"Lost connection with prefill instance (bootstrap_addr: {failed_bootstrap_addr}), "
```

```
f"{len(affected_rooms)} requests affected"  
)
```

评论区精华

无 review 评论，但 PR 描述中作者主动分析了各后端的访问模式，指出 Mori 的 `_cleanup_room_tracking` 是唯一不安全的变异方，并强调该修复属于加固而非修复活 bug，同时验证了 `list()` 的原子性优于 Python 层级别理解。

- 暂无高价值评论线程

风险与影响

- 风险：风险低。改动仅涉及一行核心逻辑，行为不变，不会引入回归。但需注意：该修复依赖 `list()` 的原子性，若未来修改为其他快照方式（如理解 `comprehension`）可能重新引入竞态。此外，未覆盖 `mori` 接入场景的测试，若未来启用 `mori` 心跳线程，仍需验证。
- 影响：影响范围小，仅影响节点故障处理路径，属于控制面。对用户无感知，但能增强系统稳定性，避免故障检测静默失效。对团队而言，减少了跨后端的隐含依赖，便于未来接入 `mori`。
- 风险标记：核心路径变更，缺少测试覆盖，依赖 `list` 原子性

关联脉络

- PR #27010 [HiCache] Fix PP inconsistency with HiCache L3 (#22607): 同为 KV cache 管理相关修复，涉及调度与一致性，虽模块不同但可参考类似的锁与一致性处理。