

PR #36029 完整报告

sgl-project/sglang

fix(disagg): refresh stale prefill bootstrap metadata

合并时间: 2026-08-26 03:29

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36029>

执行摘要

- 一句话: 修复 prefill 重启后解码端复用旧端口, 缓存代际按对象身份失效
- 推荐动作: 值得精读。该 PR 展示了一个典型的“缓存失效需精确到对象身份”的并发设计: 通过记录谁引用了哪一代缓存、在失效时用 is 比较避免误删并发替换, 是处理分布式 / 多接收者缓存失效的佳例。同时, 将 `_connect_to_bootstrap_server` 移入 try 块并在发送失败时同步失效, 体现了错误恢复与缓存一致性联动的思路。建议重点关注 `_setup_bootstrap_infos` 中 `setdefault` 与对象身份判断的组合用法。

功能与动机

PR body 指出: Decode workers 缓存的 prefill bootstrap 元数据中包含临时 per-rank 端口, 当 prefill 进程以相同 host 和 bootstrap 地址重启后, rank 端口改变但缓存键不变, 后续请求会无限期复用旧端口。前一个修复 PR #31144 虽然限制了失败的 ZMQ send, 但缓存代际仍保留, 导致每个后续请求继续失败。本 PR 的目标是精确失效“仅当前接收者使用过”的缓存条目, 同时避免误删其他接收者并发写入的新代际。

实现拆解

1. 记录接收者使用的缓存条目: 在 `CommonKVReceiver.__init__` 中新增 `_connection_pool_entries: Dict[str, List[Dict]]`, 用于保存该接收者从 `connection_pool` 选中的条目 (key 为 `bootstrap_key`, value 为缓存列表对象)。
2. 重构缓存读写路径: `_setup_bootstrap_infos` 中把 `if bootstrap_key not in connection_pool` 改为在 `connection_lock` 保护下 `get`; 写入时使用 `setdefault` 并比对对象身份, 若已有并发写入的新代际则采用对方的值, 同时更新 `_connection_pool_entries`。
3. 新增身份安全失效方法: `invalidate_cached_bootstrap_infos()` 在锁内遍历 `_connection_pool_entries`, 仅当 `connection_pool.get(key)` is 目标对象时才删除, 随后清空本地追踪; 这样不会误删另一个接收者刚写入的替换代际。
4. 接入失败路径: `_setup_bootstrap_infos` 的拉取失败、`_register_kv_args` 失败以及 `_check_waiting_timeout` 超时分支均调用失效方法; Mooncake、MORI、NIXL 的 `send_metadata` 和 `_register_kv_args` 把 `_connect_to_bootstrap_server` 移入 try 块, 并在 `zmq.ZMQError` 时调用失效方法。
5. 配套测试: 新增 `test/registered/unit/disaggregation/test_receiver_connection_pool.py` (注册到 `base-a-test-cpu`), 覆盖身份安全失效、并发替换保留、多 CP 条目、路由重拉、

等待超时失效；test_nixl_backend_basic.py 的 fixture 补上 _connection_pool_entries = {} 初始化。

关键文件：

- python/sglang/srt/disaggregation/common/conn.py（模块 分拆连接；类别 source；类型 core-logic；符号 invalidate_cached_bootstrap_infos）：核心修改文件：新增 _connection_pool_entries 追踪与 invalidate_cached_bootstrap_infos() 身份安全失效逻辑，并重构 _setup_bootstrap_infos 的缓存读写路径。
- test/registered/unit/disaggregation/test_receiver_connection_pool.py（模块 分拆测试；类别 test；类型 test-coverage；符号 _ConcreteReceiver, poll, failure_exception, _receiver）：新增的 CPU 单元测试，完整覆盖失效逻辑的关键分支，是验证修复正确性的核心证据。
- python/sglang/srt/disaggregation/mooncake/conn.py（模块 传输后端；类别 source；类型 core-logic）：将 _connect_to_bootstrap_server 移入 try 块，并在 ZMQ 发送失败时调用 invalidate_cached_bootstrap_infos，统一错误恢复行为。
- python/sglang/srt/disaggregation/mori/conn.py（模块 传输后端；类别 source；类型 core-logic）：与 Mooncake 相同的错误恢复修正，确保 MORI 后端在发送失败时也触发缓存失效。
- python/sglang/srt/disaggregation/nixl/conn.py（模块 传输后端；类别 source；类型 core-logic）：与 Mooncake、MORI 相同的错误恢复修正，NIXL 后端同样接入缓存失效。
- test/registered/unit/disaggregation/test_nixl_backend_basic.py（模块 NIXL 测试；类别 test；类型 test-coverage）：测试 fixture 需要补上 _connection_pool_entries 初始化，以兼容新增的失效逻辑。

关键符号：invalidate_cached_bootstrap_infos, _setup_bootstrap_infos, _check_waiting_timeout, send_metadata, _register_kv_args

关键源码片段

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

核心修改文件：新增 _connection_pool_entries 追踪与 invalidate_cached_bootstrap_infos() 身份安全失效逻辑，并重构 _setup_bootstrap_infos 的缓存读写路径。

```
def invalidate_cached_bootstrap_infos(self) -> None:
    # 只在锁内删除本接收者实际引用过的缓存代际。
    # 用对象身份 (is) 比较，避免误删其他接收者并发写入的替代代际。
    with self.kv_mgr.connection_lock:
        for bootstrap_key, bootstrap_infos in self._connection_pool_entries.items():
            if self.kv_mgr.connection_pool.get(bootstrap_key) is bootstrap_infos:
                del self.kv_mgr.connection_pool[bootstrap_key]
        # 清空本地追踪，避免同一接收者再次调用时重复删除。
        self._connection_pool_entries.clear()

def _setup_bootstrap_infos(self):
```

```

all_bootstrap_infos = []
# 缓存 key 由 bootstrap_addr、prefill_dp_rank、prefill_cp_rank、target_tp_rank 唯一确定
for target_cp_rank in self.target_cp_ranks:
    bootstrap_key = f"{self.bootstrap_addr}_{self.prefill_dp_rank}_{target_cp_rank}_{self.target_
tp_rank}"

    with self.kv_mgr.connection_lock:
        cached_bootstrap_infos = self.kv_mgr.connection_pool.get(bootstrap_key)

    if cached_bootstrap_infos is None:
        # 未命中缓存 → 逐 rank 从 bootstrap server 拉取
        bootstrap_infos = []
        for target_tp_rank in self.target_tp_ranks:
            for target_pp_rank in reversed(self.target_pp_ranks):
                bootstrap_info = self._get_bootstrap_info_from_server(
                    self.prefill_dp_rank,
                    target_cp_rank,
                    target_tp_rank,
                    target_pp_rank,
                )
                if bootstrap_info is None:
                    # 拉取失败 → 标记失败并立即清除本接收者用过的缓存代际
                    self.kv_mgr.record_failure(
                        self.bootstrap_room,
                        f"Failed to fetch bootstrap info from {self.bootstrap_addr}",
                    )
                    self.kv_mgr.update_status(self.bootstrap_room, KVPoll.Failed)
                    self.bootstrap_infos = None
                    self.invalidate_cached_bootstrap_infos()
                return
            # 省略 is_dummy 等字段处理, 逻辑与旧版一致
            bootstrap_infos.append(bootstrap_info)

        self.bootstrap_infos = bootstrap_infos
        self._connection_pool_entries[bootstrap_key] = self.bootstrap_infos

    if not self._register_kv_args():
        # 注册失败 → 缓存不能残留失败代际, 立即失效
        self.invalidate_cached_bootstrap_infos()
        return

    with self.kv_mgr.connection_lock:
        # setdefault 保证并发下只保留一份; 若已有其他 receiver 写入新代际, 则采用对方的
        cached_bootstrap_infos = self.kv_mgr.connection_pool.setdefault(
            bootstrap_key, self.bootstrap_infos
        )
        if cached_bootstrap_infos is not self.bootstrap_infos:
            self.bootstrap_infos = cached_bootstrap_infos

```

```

        self._connection_pool_entries[bootstrap_key] = self.bootstrap_infos
    else:
        self.bootstrap_infos = cached_bootstrap_infos
        self._connection_pool_entries[bootstrap_key] = self.bootstrap_infos

    assert len(self.bootstrap_infos) > 0
    all_bootstrap_infos.extend(self.bootstrap_infos)

self.bootstrap_infos = all_bootstrap_infos

```

test/registered/unit/disaggregation/test_receiver_connection_pool.py

新增的 CPU 单元测试，完整覆盖失效逻辑的关键分支，是验证修复正确性的核心证据。

```

class TestReceiverConnectionPool(CustomTestCase):
    def test_invalidate_preserves_concurrent_replacement_generation(self):
        # 模拟场景：另一个 receiver 已用新端口（2001）替换了同一 key 的缓存，
        # 本 receiver 持有的 stale 代际（1001）应当被安全丢弃，但不能误删新代际。
        stale = [{"rank_ip": "10.0.0.1", "rank_port": 1001}]
        replacement = [{"rank_ip": "10.0.0.1", "rank_port": 2001}]
        receiver = _receiver(
            {"key": replacement}, # connection_pool 当前存的是新代际
            {"key": stale}, # 本 receiver 引用的旧代际
        )

        receiver.invalidate_cached_bootstrap_infos()

        # 只有旧代际被移除，新代际保留
        self.assertEqual(receiver.kv_mgr.connection_pool, {"key": replacement})

    def test_next_receiver_refetches_after_invalidation(self):
        # 失效后，下一个 receiver 应重新调用 _get_bootstrap_info_from_server 拉取新端口
        stale = [{"rank_ip": "10.0.0.1", "rank_port": 1001}]
        connection_pool = {"prefill:8998_0_0_0": stale}
        stale_receiver = _receiver(connection_pool, {"prefill:8998_0_0_0": stale})
        stale_receiver.invalidate_cached_bootstrap_infos()

        receiver = _fetching_receiver(connection_pool) # fetch_count 初始为 0
        receiver._setup_bootstrap_infos()

        self.assertEqual(receiver.fetch_count, 1) # 证明确实重新拉取
        self.assertEqual(receiver.bootstrap_infos[0]["rank_port"], 2001)

```

评论区精华

ShangmingCai 在 [_check_waiting_timeout](#) 新增失效调用处提问：“what if prefill is just slow, not dead?”（如果 prefill 只是慢，而不是死掉怎么办？），担心超时失效会误伤响应慢的 prefill。该问题未在 thread 内直接回复，但从实现看，超时意味着当前接收者已放弃该次请求，失效后下个请求会重新拉取；若 prefill 只是慢，重新拉取仍可成功并自愈，因此不会造成永久性错误。ShangmingCai 最终批准并留言：“Overall LGTM, let us check the CI.”

- 等待超时失效是否会误杀慢 prefill? (correctness): 未在 thread 内直接回复, 但实现上失效只影响缓存复用, 下个请求会重新拉取; 若 prefill 可用则自动恢复, 不会造成永久性失败。

风险与影响

- 风险: 并发安全: 失效方法在 connection_lock 内遍历和删除, 避免与 _setup_bootstrap_infos 的读写竞争; 锁粒度小, 条目数通常等于 CP 数, 不会成为热点。
对象身份依赖: 失效依赖 Python is 比较, 要求缓存中保存的是原始列表对象; 当前所有写入路径都直接保存原对象, 不存在序列化重建, 行为正确, 但未来若有克隆写入需特别注意。
超时误杀: 等待超时立即失效可能对慢 prefill 触发一次额外重拉, 但重拉成本低且结果正确, 属于可接受的权衡。影响范围: 只影响 PD 分离的错误恢复路径, 不改变正常数据面; 三个传输后端行为对齐, 统一处理 ZMQ 发送失败。
- 影响: 对用户而言, prefill 重启后解码端请求将不再无限失败, 而是自动刷新并恢复, 显著提升 PD 分离场景的鲁棒性; 对系统而言, happy path 仅增加短锁保护的缓存查找 / 插入操作, 无额外数据面开销; 对团队而言, 统一了 Common/Mooncake/MORI/NIXL 四个后端的失效逻辑, 降低了后续维护成本, 并通过 CPU 测试锁定了关键行为。
- 风险标记: 核心错误恢复路径, 按对象身份失效, 跨后端统一, 锁内失效

关联脉络

- PR #36351 fix(disagg): snapshot affected rooms before iterating outside the lock: 同一模块 (disaggregation/common/conn.py) 的并发正确性修复, 与本 PR 都在处理连接池跟踪与锁语义。