

PR #36025 完整报告

sgl-project/sglang

[AMD][MORI] Deduplicate CP-replicated state transfers

合并时间: 2026-08-25 05:43

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36025>

执行摘要

- 一句话: MORI 下仅 CP rank 0 发送复制状态, 传输流量降 85%
- 推荐动作: 值得快速浏览: 整体改动仅 4 个文件、71 行, 核心是 `_should_skip_cp_replicated_state_transfer()` 的策略上移与 MORI `send()` 的去重接入。对从事 PD 传输或 AMD 后端的工程师, 公共策略 + layer split 例外的设计值得借鉴; 普通使用者无需深入。若后续要在 MORI/Mooncake 之外的新后端复用, 注意其前提是「CP all-gather 后 state 全等」。

功能与动机

PR body 指出: 开启 `SGLANG_DISAGGREGATION_ALL_CP_RANKS_TRANSFER=1` 的 Prefill CP 场景下, MORI 将 KV pages 按 CP rank 切分, 但 `state_indices` 原样传给每个 rank, 导致同一份 state 被重复传输 `cp_size` 次; 而 Prefill CP 阶段会先在全局 token 序上做 all-gather, 每个 rank 本就持有完整 state。本 PR 是 Mooncake 侧同类修复 (PR#32620) 的 MORI 版本, 目标是把 state 复制流量降为单份。

实现拆解

1. 策略上移: 在 `python/sglang/srt/disaggregation/common/conn.py` 的 `CommonKVManager` 新增 `_should_skip_cp_replicated_state_transfer()`, 用 `attn_cp_size > 1`、`attn_cp_rank != 0`、`enable_dsa_cache_layer_split` 三个条件判定是否跳过 state 传输。选择放在公共基类是为了让 Mooncake 与 MORI 共用同一语义, 避免两份内联判断漂移。
2. Mooncake 复用: `mooncake/conn.py` 的 `_get_dsa_cache_transfer_skip_flags()` 删除原来的内联条件, 改为调用公共方法, 同时移除不再使用的 `get_parallel` 导入, 行为等价, 消除重复实现。
3. MORI 去重: `mori/conn.py` 的 `MoriKVManager.send()` 在 `_prepare_send_indices` 之后、`_normalize_state_indices_per_component` 与 `_record_transfer_indices` 之前, 把 `state_indices` 替换为 `None` (当公共策略判定需要跳过时); KV 分片、aux 数据、完成通知路径完全不变, 并保留 `cache layer-split` 下每 rank 发送自己 state 层的行为。
4. 测试与验证: `test_disaggregation_wire.py` 新增 `TestCPReplicatedStateTransfer`, 用 5 组参数化用例覆盖单 rank、rank 0、非零 rank、layer split 四种情形, 并断言 Mooncake 的 `_get_dsa_cache_transfer_skip_flags` 返回 (`False`, `True`), 保证重构后行为等价。PR body 另附 MI355X 上 CP8 的准确率与流量实测。

关键文件：

- python/sglang/srt/disaggregation/common/conn.py (模块 公共传输层；类别 source；类型 core-logic；符号 `_should_skip_cp_replicated_state_transfer`)：新增 `_should_skip_cp_replicated_state_transfer()` 公共策略，是本 PR 的核心设计：把 CP 复制状态去重逻辑从 Mooncake 私有实现提升为所有传输后端可复用的基类方法，并文档化 layer split 例外。
- python/sglang/srt/disaggregation/mori/conn.py (模块 MORI 后端；类别 source；类型 core-logic；符号 `send`)：MORI 发送路径 `send()` 是去重的实际落地位置：在 enqueue 与记账前把非零 CP rank 的 `state_indices` 置空，同时保住 KV 分片、aux 与 layer split 语义。
- python/sglang/srt/disaggregation/mooncake/conn.py (模块 Mooncake 后端；类别 source；类型 dependency-wiring；符号 `_get_dsa_cache_transfer_skip_flags`)：重构对象：删除 `_get_dsa_cache_transfer_skip_flags()` 里的内联 CP 跳过条件与 `get_parallel` 导入，改为调用公共策略，验证行为等价并消除实现漂移。
- test/registered/unit/disaggregation/test_disaggregation_wire.py (模块 传输测试；类别 test；类型 test-coverage；符号 `TestCPReplicatedStateTransfer`, `test_only_nonzero_cp_ranks_without_layer_split_skip_state`, `test_mooncake_uses_common_cp_state_policy`)：新增 `TestCPReplicatedStateTransfer` 单测，用 5 组参数化用例覆盖单 rank、rank 0、非零 rank 与 layer split 4 类场景，并验证 Mooncake 复用公共策略后 skip 行为不变，是本次改动的回归保障。

关键符号：`_should_skip_cp_replicated_state_transfer`, `send`, `_get_dsa_cache_transfer_skip_flags`

关键源码片段

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

新增 `_should_skip_cp_replicated_state_transfer()` 公共策略，是本 PR 的核心设计：把 CP 复制状态去重逻辑从 Mooncake 私有实现提升为所有传输后端可复用的基类方法，并文档化 layer split 例外。

```
# 公共策略：判断当前 prefill rank 是否需要跳过 CP 复制状态的传输。
# 背景：Prefill CP 阶段先做 all-gather 再写入 state 池，
# 故每个 CP rank 持有的 state 完全相同；当各 rank 各自发送 KV 分片时，
# 只需 rank 0 发送全量 state，非零 rank 跳过即可避免流量放大 cp_size 倍。
# 例外：DSA cache layer split 开启时每个 rank 持有不同的 state 层，
# 必须由各 rank 分别发送自己拥有的部分，因此不能跳过。
def _should_skip_cp_replicated_state_transfer(self) -> bool:
    """Whether this prefill rank should omit CP-replicated state.
```

```

    Prefill CP materializes global token order before writing state pools, so
    every CP rank holds the same state. When all CP ranks transfer their KV
    shards, only rank 0 needs to send that state. Cache layer split is the
    exception because each CP rank owns different state layers.
```

```

"""
return (
    self.attn_cp_size > 1 # CP 规模大于 1 才存在复制语义
    and self.attn_cp_rank != 0 # rank 0 负责发送全量 state
    and not get_parallel().enable_dsa_cache_layer_split # layer split 例外
)

```

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

MORI 发送路径 `send()` 是去重的实际落地位置：在 `enqueue` 与记账前把非零 CP rank 的 `state_indices` 置空，同时保住 KV 分片、aux 与 layer split 语义。

```

def send(
    self,
    kv_indices: npt.NDArray[np.int32],
    state_indices: Optional[List] = None,
    num_kv_tokens: Optional[int] = None,
):
    # 统一的发送前准备：切 KV 分片、定位索引切片、标记最后一块并计算整体跳过
    kv_indices, index_slice, is_last_chunk, should_skip = (
        self._prepare_send_indices(kv_indices, state_indices)
    )
    if should_skip:
        return

    # 核心去重点：Prefill CP 下所有 rank 持有相同 state，仅 rank 0 需要发送。
    # 非零 CP rank 在 enqueue 与记账前把 state_indices 置空，KV 分片不受影响。
    transfer_state_indices = (
        None
        if self.kv_mgr._should_skip_cp_replicated_state_transfer()
        else state_indices
    )

    # 只在最后一块按组件归一化 state 索引，供对端正确还原状态布局
    normalized_state = (
        _normalize_state_indices_per_component(transfer_state_indices)
        if is_last_chunk
        else None
    )
    # 记账与入队统一使用裁剪后的 state，保证统计与传输一致
    self._record_transfer_indices(kv_indices, transfer_state_indices)
    wait_event = getattr(self, "_early_send_wait_event", None)
    self._early_send_wait_event = None
    self.kv_mgr.enqueue_transfer(
        _TransferChunk(
            sender=self,
            kv_indices=kv_indices,
            index_slice=index_slice,
            is_last_chunk=is_last_chunk,
            aux_index=self.aux_index if is_last_chunk else None,

```

```
        normalized_state=normalized_state,  
        wait_event=wait_event,  
    )  
)  
self._maybe_finalize_if_room_failed()
```

评论区精华

该 PR 没有实质 review 评论：HaiShaw 直接 APPROVED，唯一的 issue 评论是 /tag-and-rerun-ci 触发 CI 重跑。PR body 中的设计决策（只让 rank 0 发送全量 state、layer split 例外、KV 分片与完成通知路径不变）由作者说明并附 MI355X 实测数据背书，未产生争议。CI 状态显示 Base 测试通过，Extra 与 AMD ROCm 7.2 两个 job 失败，失败原因未在材料中说明。

- 暂无高价值评论线程

风险与影响

- 风险：

1. 正确性依赖「CP all-gather 后各 rank state 全等」这一前提：一旦未来某种 state 类型不再被 all-gather 复制（例如硬件私有状态），_should_skip_cp_replicated_state_transfer() 会让非零 rank 漏发数据，导致 decode 侧状态缺失；该函数位于公共基类，任何子类扩展 state 类型时都要重新审视该前提。
2. MORI 在 send() 中把 state_indices 置 None 后再记账，若未来同一条路径另有消费 state_indices 的旁路（如重试、统计），可能拿到裁剪后的数据。
3. Mooncake 重构移除了 get_parallel 导入，若存在从 mooncake/conn.py 间接导入 get_parallel 的外部代码会报 ImportError，仓库内未见此类调用。
4. 测试只覆盖 CPU 单测与策略分支，未把 CP8 端到端传输测试入库，回归保障依赖 PR body 的人工准确率验证；Extra 与 AMD ROCm CI 失败原因未说明。- 影响：该 PR 只影响 PD 场景下启用 Prefill CP 的 MORI 与 Mooncake 传输路径。实测（MI355X、DeepSeek-V4-Pro、Prefill CP8 / Decode TP8）：kv_transfer_total_mb 降低 84.97%，可显著缓解跨节点与互联带宽压力，为更大 CP 规模铺路；TTFT 与输入吞吐几乎不变，说明该链路当前不是延迟瓶颈。对代码结构而言，CP 复制状态策略从 Mooncake 私有逻辑提升为 CommonKVManager 公共策略，后续新传输后端可直接复用，减少实现漂移。无模型 forward、无 kernel、无 API 变更，对普通推理用户透明。- 风险标记：PD 传输核心路径，依赖 rank 0 全量状态，端到端传输测试未入库，公共策略影响多后端

关联脉络

- PR #32620 Deduplicate CP-replicated state transfers (Mooncake): 本 PR body 明确说明其是 #32620 的 MORI counterpart，将 Mooncake 侧已有的 CP 复制状态去重策略推广到 MORI；该标题为按 body 描述推断，仓库提供的历史 PR 列表中未包含该条目。
- PR #35957 Fix recurrent state loss on decode retraction: 同属 PD state 生命周期与传输正确性修复线，改动 schedule_batch 的 retraction 状态备份与传输，与本 PR 的 state 传输去重互为补充。

- PR #35840 Add PD test for inkling with mxfp8 KV: 同为 disaggregation 传输链路新增测试覆盖，扩展 PD state/KV 传输的回归保障。