

PR #47495 完整报告

vllm-project/vllm

[Bugfix][KV-transfer] MoRIIO: retry RDMA send-queue-full backpressure instead of failing the read

合并时间: 2026-07-17 04:02

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47495>

执行摘要

- 一句话: 修复 MoRIIO RDMA 发送队列满时重试读请求
- 推荐动作: 值得精读, 尤其关注瞬态错误重试策略和 ACK 缓冲机制的设计权衡。
_is_sq_full_status 的实现依赖字符串匹配, 建议未来考虑更健壮的检测方式 (如 mori 库的错误码)。

功能与动机

在高并发下, 每个 QP 的 RDMA 发送队列是硬件限制的 (如 bnxt max_qp_wr=4351), `read_remote_data` 同步提交 READ 请求时如果 SQ 满则立即返回 Failed 状态, 此前该状态被当作传输失败, 导致预填充释放 block、丢弃请求, 最终因超时中止。实际上 CQ 轮询线程会在几毫秒内释放 SQ 深度, 请求本可成功。

实现拆解

1. 缓冲未映射的 ACK: 在 `MoRIIOConnectorWorker.__init__` 中新增 `_pending_unmapped_acks` 列表, `get_finished` 先从该列表取 ACK, 再合并 `pop_finished_req_ids` 的新 ACK, 对于 `transfer_id` 不在 `transfer_id_to_request_id` 中的 ACK 不再直接警告丢弃, 而是追加到缓冲列表等待下次轮询重试, 解决通知先于 `start_load_kv` 到达导致的竞争。
2. SQ full 重试逻辑: 在 `_read_blocks` 中, 当 `status.Failed()` 且消息包含 SQ full (通过 `_is_sq_full_status` 静态方法检测) 时, 不直接标记失败, 而是退避重试 READ, 重试总时间受 `transfer_timeout` 限制。若超时仍未成功, 则将失败状态存储, 由 `get_finished` 按非致命方式处理。非 SQ full 的失败行为不变。
3. 放宽 block ID 校验: `moriio_layout.py` 中 `compute_block_transfer_offsets` 原要求 `local_block_ids` 长度严格等于 `remote_block_ids`, 现改为只拒绝 `local_block_ids` 长于 `remote_block_ids`, 允许短 / 空列表 (对应 READ 模式的纯释放路径)。
4. 测试适配: 更新 `test_moriio_kv_layout.py` 中的测试函数名为 `test_local_block_ids_longer_than_remote_raises_value_error`, 新增 `test_empty_local_block_ids_is_free_only_noop`; 在 `test_moriio_tp_ack.py` 的 `test_worker_get_finished_counts_structured_release_fan_in` 中为手工构造的 worker 设置 `_pending_unmapped_acks = []`, 避免属性不存在错误。

关键文件：

- `vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_connector.py`（模块 KV 传输；类别 source；类型 core-logic；符号 `_is_sq_full_status`）：核心变更文件：实现 SQ full 重试逻辑（`_is_sq_full_status + _read_blocks` 修改）和未映射 ACK 缓冲（`_pending_unmapped_acks + get_finished` 修改），+70/-9。
- `vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_layout.py`（模块 KV 传输；类别 source；类型 core-logic）：放宽 `compute_block_transfer_offsets` 的校验，允许 `local_block_ids` 短于 `remote_block_ids`，支持 READ 模式纯释放路径。
- `tests/v1/kv_connector/unit/test_moriiio_kv_layout.py`（模块 测试；类别 test；类型 test-coverage；符号 `test_block_id_length_mismatch_raises_value_error`，`test_local_block_ids_longer_than_remote_raises_value_error`，`test_empty_local_block_ids_is_free_only_noop`）：测试更新：更新原有测试函数名与匹配字符串，新增空 `local_block_ids` 的 no-op 测试。
- `tests/v1/kv_connector/unit/test_moriiio_tp_ack.py`（模块 测试；类别 test；类型 test-coverage）：修复手工构造 worker 时未设置 `_pending_unmapped_acks` 导致的 `AttributeError`，仅一行变更。

关键符号：`_is_sq_full_status`, `get_finished`, `compute_block_transfer_offsets`, `_read_blocks`

关键源码片段

`vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_connector.py`

核心变更文件：实现 SQ full 重试逻辑（`_is_sq_full_status + _read_blocks` 修改）和未映射 ACK 缓冲（`_pending_unmapped_acks + get_finished` 修改），+70/-9。

```
# vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_connector.py

# 在 __init__ 中新增：缓冲 READ 完成 ACK 的列表
# 当 decode 的 release ACK 在 transfer_id_to_request_id 建立之前到达时，
# 先缓冲在此，每次 get_finished 轮询重试，避免丢失导致 block 泄漏。
self._pending_unmapped_acks: list = []

# 静态方法：检测 RDMA 发送队列满的瞬态错误
@staticmethod
def _is_sq_full_status(status) -> bool:
    """True if a MoRIIO transfer status is a transient RDMA send-queue-full
    rejection (retryable backpressure), not a terminal failure."""
    try:
        # mori 将 SQ full 表示为 Failed() 且消息包含 "SQ full"
        return bool(status.Failed()) and "SQ full" in (status.Message() or "")
    except Exception:
        return False

def get_finished(self) -> tuple[set[str], set[str]]:
    # 合并缓冲区和新 ACK，然后清空缓冲区
```

```

finished_acks = self._pending_unmapped_acks + list(
    self.moriio_wrapper.pop_finished_req_ids()
)
self._pending_unmapped_acks = []
for ack in finished_acks:
    transfer_id = ack if isinstance(ack, str) else ack.transfer_id
    if transfer_id not in self.transfer_id_to_request_id:
        # 映射未就绪, 缓冲并留待下次轮询 (不丢弃)
        self._pending_unmapped_acks.append(ack)
        continue
    # ... 原有 resolve 逻辑

def _read_blocks(self, ...):
    # ... 发送 READ 后
    if not status.Succeeded():
        if self._is_sq_full_status(status):
            # SQ full: 退避重试, 由 transfer_timeout 限制总时间
            if self._retry_read(...):
                return
        # 其他失败或超时: 走原有失败处理
    # ...

```

vllm/distributed/kv_transfer/kv_connector/v1/moriio/moriio_layout.py

放宽 compute_block_transfer_offsets 的校验, 允许 local_block_ids 短于 remote_block_ids, 支持 READ 模式纯释放路径。

```
# vllm/distributed/kv_transfer/kv_connector/v1/moriio/moriio_layout.py
```

```

def compute_block_transfer_offsets(...):
    # 之前要求长度严格相等, 现在允许 local 更短
    # 因为 READ 模式下 decode 只需释放部分 block
    if len(local_block_ids) > len(remote_block_ids):
        raise ValueError(
            "local_block_ids longer than remote_block_ids: "
            f"{len(local_block_ids)} > {len(remote_block_ids)}"
        )
    # ... 后续逻辑基于 len(local) 循环, 自动处理短列表

```

评论区精华

CI 中的预提交检查因 pip-compile-xpu 从 pytorch xpu wheel 镜像获取 pyzmq 时出现 503 Service Unavailable 而失败, 与代码本身无关, 作者请求 maintainer 重跑 CI。另外, **V1 Core + KV + Metrics** 单元测试失败的原因是手工构造的 worker 未初始化 `_pending_unmapped_acks` 属性, 作者快速提交补丁修复 (0ca33d79)。

- 单元测试失败: 缺少 `_pending_unmapped_acks` 属性 (testing): 提交 0ca33d79 修复, 在测试中初始化该属性。
- 预提交检查失败: pytorch xpu wheel 镜像 503 (other): 由 maintainer 重跑后通过。

风险与影响

- 风险:

1. 重试循环可能增加延迟: 如果持续 SQ full 直到 transfer_timeout 超限, 会占用更多时间, 但这是合理退避, 不会无限阻塞。
2. SQ full 判断依赖字符串匹配: _is_sq_full_status 通过检查 status.Message() 是否包含 SQ full 来判断, 该字符串依赖 mori 库的异常消息格式, 未来库升级可能变更, 缺少防御性适配。
3. 缓冲 ACK 带来内存风险: 极端情况下如果映射持续不建立, _pending_unmapped_acks 可能无限增长, 但 transfer_timeout 最终会失败并清理映射。
4. 放宽 length 校验: 允许 local_block_ids 短于 remote_block_ids 可能隐藏真正的问题 (如广播 bug), 但通过只允许短于 (不允许长于) 来保留对异常情况的报错。 - 影响: 直接影响使用 MoRIIO KV 传输的离散预填充 / 解码 (P/D) 部署, 尤其是高并发多解码 / MTP 场景。此前 SQ full 会导致请求超时、KV block 泄漏、预填充缓存死锁, 本修复消除了这些故障, 使系统在高并发下稳定运行。对不使用 MoRIIO 的用户无影响。 - 风险标记: SQ full 重试依赖字符串匹配, 缓冲 ACK 潜在无限增长, 放宽长度校验可能掩盖异常

关联脉络

- PR #48209 Vectorize prep xfer list creation: 同一 MoRIIO 模块的性能优化, 与当前 PR 共同改进高并发 KV 传输的稳定性与效率。
- PR #48717 [Misc][Nixl] Unify _logical_to_remote_kernel_block_ids: 另一 KV 连接器 (Nixl) 的类似重构, 反映团队对 KV 传输路径的持续优化。