

PR #46290 完整报告

vllm-project/vllm

[ROCm][P/D] Fix MoRIIO WRITE mode for mixed KV layouts

合并时间: 2026-06-23 12:12

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46290>

执行摘要

- 一句话: 修复 MoRIIO WRITE 混合 KV 布局正确性问题
- 推荐动作: 值得精读: 此 PR 展示了如何在不改动上层调度逻辑的前提下, 在分布式 KV 传输中处理异构缓存几何。moriiio_layout.py 中的内核块布局检测算法和 moriiio_engine.py 中的写入完成跟踪机制值得借鉴。使用 MoRIIO WRITE 模式的团队应关注此 PR 的变更。

功能与动机

如 PR 描述所述, 前一个 PR #46039 使 MoRIIO READ 模式支持了混合 KV 缓存布局, 但 WRITE 模式仍存在两个正确性问题:

1) 跨层重用了 request-wide 的 offset tuple, 而不同层 (如密集 K/V 层 vs 仅索引层) 可能有不同的缓存几何; 2) 计数注册的缓存张数而非实际由 WRITE hook 调度的层来完成 WRITE。本 PR 针对这些问题进行修复, 确保混合缓存布局下 WRITE 的正确性。

实现拆解

1. 按几何计算偏移量 (moriiio_layout.py): 新增 `_spec_dim_matches`、`_kernel_layout_matches`、`_select_kernel_block_layout` 函数, 自动检测内核块 KV 缓存几何 (支持分离 / 交错布局), 在 `get_layer_transfer_geometry` 中区分块大小所在轴, 计算正确的 `block_stride` 和 `kernel_blocks_per_block`。
2. 缓存 WRITE 偏移计划 (moriiio_engine.py): 引入 `_get_write_geometry_key` 函数, 基于张量形状、步长和 dtype 生成键; MoRIIOWriter 新增 `_scheduled_writes`、`_scheduled_layers`、`_sealed_writes` 字典, 按 `transfer_id` 跟踪每个传输的调度写入层数和密封计数。`schedule_write` 返回 `bool` 标记是否真正调度, `seal_pending_transfers` 在模型前向后密封期望的写入数。
3. 修复完成逻辑 (moriiio_engine.py): 新增 `_finalize_if_complete` 检查调度写入是否全部完成, 只有完成后才触发通知和释放。新增 `_clear_transfer_state` 清理传输状态, `_is_transfer_terminal` 检查传输是否已完成 (避免重复调度)。
4. 连接器侧配套 (moriiio_connector.py): 实现 `wait_for_save` 非空 (仅在 WRITE 模式下等待); 新增 `_send_transfer_release` 发送结构化 release 消息, `_release_write_prefill_blocks` 在写入完成后释放预填充块。`update_state_after_alloc` 中从 `kv_transfer_params` 获取 remote 地址而非仅解析 `request_id`。

5. 数据结构更新 (`moriiio_common.py`) : `RemoteAllocInfo` 增加 `writes_expected`、`completion_*` 字段和 `transfer_offsets` 字典 (按几何键缓存偏移量), 支持完成通知去重。
6. 单元测试 (`test_moriiio_kv_layout.py`、`test_moriiio_connector.py`) : 新增 577 行和 77 行测试代码, 覆盖偏移量计算、写入完成通知、结构化 / 普通消息处理、生产者块释放、内核块布局等场景。

关键文件:

- `vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_engine.py` (模块 写入引擎; 类别 `source`; 类型 `core-logic`; 符号 `_get_write_geometry_key`, `schedule_write`, `is_scheduled`, `seal_pending_transfers`) : 核心写入引擎, 新增按几何计算偏移量和写入完成跟踪。
- `vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_connector.py` (模块 连接器; 类别 `source`; 类型 `core-logic`; 符号 `_send_transfer_release`, `_release_write_prefill_blocks`, `wait_for_save`) : 连接器层新增结构化 `release` 和预填充块释放逻辑。
- `vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_layout.py` (模块 传输布局; 类别 `source`; 类型 `core-logic`; 符号 `_spec_dim_matches`, `_kernel_layout_matches`, `_select_kernel_block_layout`) : 传输布局模块, 新增内核块几何自动检测。
- `tests/v1/kv_connector/unit/test_moriiio_kv_layout.py` (模块 布局测试; 类别 `test`; 类型 `test-coverage`; 符号 `_full_spec`, `test_separated_kv_layout_uses_kv_axis_zero_and_block_axis_one`, `_writer_with_fake_worker`, `_wrapper_for_messages`) : 单元测试覆盖新布局几何、写入完成通知、消息处理等。
- `tests/v1/kv_connector/unit/test_moriiio_connector.py` (模块 连接测试; 类别 `test`; 类型 `test-coverage`; 符号 `_find_free_port`, `_write_consumer_scheduler_for_finished_request`, `send_notify`, `test_write_mode_finished_before_alloc_releases_prefill_blocks`) : 单元测试覆盖释放行为和完成路径。

关键符号: `_get_write_geometry_key`, `schedule_write`, `is_scheduled`, `seal_pending_transfers`, `_finalize_if_complete`, `_send_transfer_release`, `_release_write_prefill_blocks`, `wait_for_save`, `_spec_dim_matches`, `_kernel_layout_matches`, `_select_kernel_block_layout`, `get_layer_transfer_geometry`

关键源码片段

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

核心写入引擎, 新增按几何计算偏移量和写入完成跟踪。

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

```
# WRITE mode 状态机关键数据结构
```

```
# 基于张量 shape、stride、dtype 生成几何键, 用于缓存偏移量
WriteGeometryKey = tuple[tuple[int, ...], tuple[int, ...], torch.dtype]
```

```
def _get_write_geometry_key(kv_cache: torch.Tensor) -> WriteGeometryKey:
```

```
return (tuple(kv_cache.shape), tuple(kv_cache.stride()), kv_cache.dtype)
```

```
class MoRIIOWriter:
```

```
    def __init__(self, worker: "MoRIIOConnectorWorker"):
```

```
        # ... 其他属性
```

```
        self._write_state_lock = threading.Lock()
```

```
        # 每个 transfer_id 已调度的写入层数
```

```
        self._scheduled_writes: dict[TransferId, int] = defaultdict(int)
```

```
        # 每个 transfer_id 已调度的层名称集合（用于去重）
```

```
        self._scheduled_layers: dict[TransferId, set[str]] = defaultdict(set)
```

```
        # 每个 transfer_id 密封后的期望写入总数（在前向之后设置）
```

```
        self._sealed_writes: dict[TransferId, int] = {}
```

```
    def schedule_write(self, task: WriteTask) -> bool:
```

```
        """调度一个写入任务，返回是否真正调度（避免重复调度和已完成传输）"""
```

```
        self.ensure_worker_started()
```

```
        if self._is_transfer_terminal(task.transfer_id):
```

```
            return False
```

```
        with self._write_state_lock:
```

```
            if self._is_transfer_terminal(task.transfer_id):
```

```
                return False
```

```
            # 跳过同一层已被调度的情况
```

```
            if task.layer_name in self._scheduled_layers[task.transfer_id]:
```

```
                return False
```

```
            self._scheduled_layers[task.transfer_id].add(task.layer_name)
```

```
            self._scheduled_writes[task.transfer_id] += 1
```

```
        self._write_task_q.put(task)
```

```
        return True
```

```
    def seal_pending_transfers(self) -> None:
```

```
        """前向完成后的密封：将当前调度计数保存为 sealed 值"""
```

```
        with self._write_state_lock:
```

```
            for xfer_id, count in self._scheduled_writes.items():
```

```
                if xfer_id not in self._sealed_writes:
```

```
                    self._sealed_writes[xfer_id] = count
```

```
            # 尝试完成所有已密封传输
```

```
            for xfer_id in list(self._sealed_writes.keys()):
```

```
                self._finalize_if_complete(xfer_id)
```

[vllm/distributed/kv_transfer/kv_connector/v1/moriiio/moriiio_connector.py](#)

连接器层新增结构化 release 和预填充块释放逻辑。

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

```
class MoRIIOConnectorScheduler:
```

```
    def _send_transfer_release(self, transfer_id: TransferId, host: str, port: int):
```

```
        """向远端发送结构化 release 消息，通知传输完成"""
```

```
        path = make_zmq_path("tcp", host, port)
```

```
        if path not in self.paths:
```

```

        ctx = zmq.Context.instance()
        sock = make_zmq_socket(
            ctx=ctx, path=path, socket_type=zmq.DEALER, bind=False
        )
        self.paths[path] = sock
    self.paths[path].send(
        msgpack.dumps({"type": "release", "transfer_id": transfer_id})
    )

def _release_write_prefill_blocks(
    self, request_id: ReqId, params: dict[str, Any]
):
    """在写入完成后释放预填充块：获取远端地址并发送 release"""
    transfer_id = params.get("transfer_id")
    if transfer_id is None:
        logger.warning(
            "Cannot release WRITE prefill blocks for request %s: "
            "missing transfer_id", request_id
        )
        return
    remote_host = params.get("remote_host")
    remote_notify_port = params.get("remote_notify_port")
    if remote_host is None or remote_notify_port is None:
        # 回退到从 request_id 解析（传统方式）
        try:
            peer_zmq = get_peer_zmq_from_request_id(
                request_id, is_producer=False
            )
            remote_host, _, remote_notify_port = parse_moriio_zmq_address(peer_zmq)
        except ValueError:
            logger.warning(...)
            return
    remote_notify_port = int(remote_notify_port)
    for tp_index in range(self.tp_size):
        target_port = remote_notify_port + get_target_offset(
            params.get("remote_dp_rank", 0), tp_index
        )
    self._send_transfer_release(transfer_id, remote_host, target_port)

```

评论区精华

Review 中仅有一条来自 [depthfirst-app\[bot\]](#) 的自动安全扫描评论，指出 `_send_transfer_release` 方法中 `host` 和 `port` 来自用户控制的 `kv_transfer_params`，可能被攻击者利用连接到内部服务，严重性为 MEDIUM，建议增加验证。该评论未在合并前得到明确回复或修改，但 PR 已合并，说明团队可能评估认为该风险在 MoRIIO 使用场景中可控。

- ZMQ 连接安全风险 (security): 未在合并前修复或回复，但该函数接收的参数由调度器内部构造，外部攻击面有限。

风险与影响

- 风险:

1. ZMQ 连接无验证 (`moriio_connector.py:399-410`) : `_send_transfer_release` 根据用户提供的 `host/port` 发起连接, 存在 SSRF 风险。但由于 MoRIIO 通常运行在受控集群内, 且 `kv_transfer_params` 由调度器内部构造, 外部攻击面较小。
 1. 新状态管理竞态 (`moriio_engine.py`) : 引入 `_write_state_lock` 保护 `_scheduled_writes`、`_scheduled_layers`、`_sealed_writes`, 但 `_write_worker_loop` 运行在独立线程中, 与主线程通过 `Queue` 通信, 需要确保锁顺序一致以防止死锁。
 2. 内核块布局自动检测误判 (`moriio_layout.py:_select_kernel_block_layout`) : 当 `shape[2]` 和 `shape[3]` 都匹配 `spec` 且值不同时会引起 `ValueError`, 但若值相等则直接返回, 可能掩盖布局歧义。
 3. 性能影响: 按传输分离状态增加了字典查找和锁开销, 但通常 WRITE 操作本身是 I/O 密集的, CPU 锁争用影响有限。 - 影响: 影响范围: 仅限使用 MoRIIO WRITE 模式进行 P/D 分离推理的用户 (主要运行在 AMD ROCm 上)。 影响程度: 修复了混合 KV 缓存布局 (如 MiniMax-M3 等模型) 下的写入正确性, 对这类模型是功能修复。内部重构不会影响 API 或外部接口。 回归风险: 对仅使用 READ 模式或单一布局的用户无影响; 单元测试覆盖了混合布局的主要路径, E2E 验证通过 GSM8K 和基准测试。
- 风险标记: ZMQ 连接无验证, 新状态管理竞态风险, 内核块布局自动检测可能误判

关联脉络

- PR #46039 Add MoRIIO READ mode layout awareness: 本 PR 是 #46039 的对称纠正, 共同实现混合 KV 布局在 MoRIIO READ 和 WRITE 模式下的完整支持。