

PR #45659 完整报告

vllm-project/vllm

[KV Connector][Mooncake] Async lookup to reduce scheduler overhead

合并时间: 2026-06-19 05:44

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/45659>

执行摘要

- 一句话: 异步 Mooncake 缓存查找, 减少调度开销
- 推荐动作: 值得精读, 尤其关注 LookupKeyClient 如何利用 ThreadPoolExecutor 实现非阻塞 RPC, 以及调度器通过返回 None 与重试机制配合的实现模式。对于需要将同步 I/O 异步化的类似场景, 本 PR 提供了一个简洁的参考样板。

功能与动机

来自 PR body:

Looking up keys in Mooncake currently happens synchronously inside `get_num_new_matched_tokens`, on the scheduler's critical path. Each lookup costs ~1-2 ms per request on average, and that latency is paid serially during scheduling.

此变更为可选异步模式, 默认保持同步行为, 用户可按需启用以减少调度器阻塞。

实现拆解

1. LookupKeyClient 异步化(`worker.py`): 引入 `ThreadPoolExecutor(max_workers=1)` 和一个 `futures` 字典, 将原来同步的 `lookup` 方法拆分为私有的 `_lookup` (实际 ZMQ 调用) 和新的 `lookup` (提交并轮询)。新增 `discard` 方法取消并清理未完成的 Future。`reset` 也通过 `executor` 提交。所有 ZMQ 调用现在都发生在单一线程中, 无需锁。
2. 调度器集成(`scheduler.py`): 在 `MooncakeStoreScheduler.__init__` 中解析 `lookup_async` 配置。`get_num_new_matched_tokens` 调用 `client.lookup` 时传入 `non_block` 标志。当异步查找未完成时返回 `(None, False)`, V1 调度器会自动重试。在 `build_connector_meta` 中, 对已完成的请求调用 `client.discard()` 以避免过时结果。
3. 返回类型适配(`connector.py`): 接口返回类型从 `tuple[int, bool]` 拓宽为 `tuple[int | None, bool]`, 符合调度器重试契约。
4. 测试覆盖: 新增 3 个单元测试, 使用 `threading.Event` 控制异步完成点, 验证非阻塞 `lookup`、`discard` 行为以及调度器重试路径。更新调度器测试中的桩类以匹配新签名。
5. 文档更新: 在 `mooncake_store_connector_usage.md` 中添加 `lookup_async` 配置说明。

关键文件:

- `vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/worker.py` (模块 `store_worker`; 类别 `source`; 类型 `core-logic`; 符号 `lookup`, `_lookup`, `reset`, `discard`): 核心变

更文件，实现 LookupKeyClient 的异步化，包括 ThreadPoolExecutor、futures 字典、非阻塞 lookup 和 discard 逻辑。

- vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/scheduler.py（模块 调度器；类别 source；类型 core-logic）：调度器集成异步查找逻辑，包括配置读取、lookup 调用修改和请求完成时 discard。
- tests/v1/kv_connector/unit/test_mooncake_store_connector.py（模块 测试；类别 test；类型 test-coverage；符号 _poll_lookup, _gated_recv, recv, test_lookup_key_client_non_block_lookup_async）：新增 3 个测试覆盖异步查找、discard 和调度器重试场景。
- vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/connector.py（模块 连接器；类别 source；类型 core-logic）：返回类型从 tuple[int, bool] 改为 tuple[int | None, bool]，以传递推迟信号。
- tests/v1/kv_connector/unit/test_mooncake_store_scheduler.py（模块 测试；类别 test；类型 test-coverage；符号 lookup）：更新 _StubLookupClient 签名以匹配新 lookup 接口，并设置 lookup_async 属性。
- docs/features/mooncake_store_connector_usage.md（模块 文档；类别 docs；类型 documentation）：添加 lookup_async 配置项说明。

关键符号：LookupKeyClient.init, LookupKeyClient._lookup, LookupKeyClient.lookup, LookupKeyClient.discard, LookupKeyClient.reset, MooncakeStoreScheduler.init, MooncakeStoreScheduler.get_num_new_matched_tokens, MooncakeStoreScheduler.build_connector_meta

关键源码片段

vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/worker.py

核心变更文件，实现 LookupKeyClient 的异步化，包括 ThreadPoolExecutor、futures 字典、非阻塞 lookup 和 discard 逻辑。

```
# vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/worker.py
# LookupKeyClient 类，支持异步前缀缓存查找

class LookupKeyClient:
    def __init__(self, vllm_config: VllmConfig):
        self.encoder = MsgpackEncoder()
        self.ctx = zmq.Context()
        socket_path = get_zmq_rpc_path_lookup(vllm_config)
        self.socket = make_zmq_socket(self.ctx, socket_path, zmq.REQ, bind=False)

        # 使用单线程执行器处理所有 ZMQ 调用，避免锁
        self.executor = ThreadPoolExecutor(
            max_workers=1, thread_name_prefix='MooncakeLookupClient'
        )
        self.futures: dict[str, Future[int]] = {}

    def _lookup(self, token_len: int, block_hashes: list[BlockHash]) -> int:
```

```

# 实际的 ZMQ 同步查找, 在 executor 线程中运行
hash_strs = [h.hex() for h in block_hashes]
hash_frames = self.encoder.encode(hash_strs)
token_len_bytes = token_len.to_bytes(4, byteorder='big')
all_frames = [LOOKUP_MSG, token_len_bytes] + list(hash_frames)
self.socket.send_multipart(all_frames, copy=False)
resp = self.socket.recv()
return int.from_bytes(resp, 'big')

def lookup(
    self,
    req_id: str,
    token_len: int,
    block_hashes: list[BlockHash],
    non_block: bool = False,
) -> int | None:
    # 非阻塞查找: 如果 non_block 为 True 且结果尚未就绪, 返回 None
    future = self.futures.get(req_id)
    if future is None:
        future = self.executor.submit(self._lookup, token_len, list(block_hashes))
        self.futures[req_id] = future
    if non_block and not future.done():
        return None # 调度器重试
    try:
        return future.result()
    except Exception as e:
        logger.error('Async Mooncake lookup failed for %s: %s', req_id, e)
        return 0
    finally:
        del self.futures[req_id]

def discard(self, req_id: str) -> None:
    # 丢弃指定请求的查找任务, 用于中止或已完成请求
    future = self.futures.pop(req_id, None)
    if future is not None:
        future.cancel()

def _reset(self) -> bool:
    # 实际的 reset 逻辑, 在 executor 中执行
    self.socket.send(RESET_MSG)
    resp = self.socket.recv()
    return bytes(resp) == RESP_OK

def reset(self) -> bool:
    # 通过 executor 异步执行 reset
    return self.executor.submit(self._reset).result()

def close(self):
    self.executor.shutdown(wait=False, cancel_futures=True)

```

```
self.socket.close(linger=0)
```

vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/scheduler.py

调度器集成异步查找逻辑，包括配置读取、lookup 调用修改和请求完成时 discard。

```
# vllm/distributed/kv_transfer/kv_connector/v1/mooncake/store/scheduler.py
class MooncakeStoreScheduler:
    def __init__(self, vllm_config: VllmConfig, kv_cache_config: KVCacheConfig):
        kvc_extra_config = vllm_config.kv_transfer_config.kv_connector_extra_config
        self.load_async = kvc_extra_config.get('load_async', True)
        self.lookup_async = kvc_extra_config.get('lookup_async', False) # 新增：默认关闭
        self.client = LookupKeyClient(vllm_config)
        # ...

    def get_num_new_matched_tokens(
        self,
        request: Request,
        num_computed_tokens: int,
    ) -> tuple[int | None, bool]:
        # 返回 (None, False) 表示异步查找未完成，调度器应重试
        token_len = request.num_tokens // self._block_size * self._block_size
        if token_len < self._block_size:
            return 0, False

        num_external_hit_tokens = self.client.lookup(
            request.request_id,
            token_len,
            request.block_hashes,
            non_block=self.lookup_async,
        )
        if num_external_hit_tokens is None:
            return None, False # 查找尚未完成，让调度器后续重试

        # 以下处理与之前相同（省略）

    def build_connector_meta(self, scheduler_output: SchedulerOutput) -> KVConnectorMetadata:
        force_skip_save = self.kv_role == 'kv_consumer'
        for finished_req_id in scheduler_output.finished_req_ids:
            self.client.discard(finished_req_id) # 丢弃已完成请求的查找 Future
        # ... 其他清理 ...
```

评论区精华

- 函数命名讨论：reviewer zhewenl 建议将方法命名为 poll_lookup。作者 ivanium 认为 poll_lookup 隐含阻塞，更倾向于 try_lookup。最终实现中保留了 lookup 一词，通过 non_block 参数区分模式。
- 锁的必要性：Dao007forever 询问是否需要 socket_lock，ivanium 解释即使未来将 client 移到调度器侧，后台线程仍可能共享 socket，因此锁仍必要。但后续 njhill 提出了更简洁的

Futures 方案，完全避免了锁。

- 架构简化建议：njhill 在 review 中建议“使用单线程 ThreadPoolExecutor 和 Futures 来管理所有 socket 访问，避免使用锁”，并示范了提交。该方案被采纳，最终实现基于 njhill 的 commit，大幅精简了状态管理（去掉了自建的队列、线程和锁，改用 executor + futures 字典）。
- 方法命名：poll_lookup vs try_lookup (style): 最终实现保留了 lookup 名称，通过 non_block 参数区分阻塞与非阻塞模式。
- 锁的必要性讨论 (design): 最终采用 njhill 的 Futures 方案，完全避免了锁，使讨论 moot。
- 使用 Future 简化异步实现 (design): 该建议被采纳，最终实现基于 Futures 方案，代码简洁且线程安全。

风险与影响

- 风险：
 - 默认关闭降低风险：lookup_async 默认 False，现有用户行为不变，无回归风险。
 - 异步一致性：若启用异步，调度器可能重试同一请求，需确保 discard() 在请求完成或中止时正确清理 Future，否则可能返回过时数据。当前实现通过 finally 块和 discard 中的 cancel() 保证。
 - 线程模型：ThreadPoolExecutor(max_workers=1) 确保所有 ZMQ 调用在单个线程中执行，避免锁竞争；但若查找请求大量积压，单线程吞吐可能成为瓶颈。由于每次查找通常 1-2ms，且与调度重叠，风险较低。
 - 返回类型放宽：tuple[int | None, bool] 的使用需要调用方（V1 调度器）已处理 None 分支，此 PR 依赖现成的 ext_tokens is None 重试机制，无需额外调度器改动。
- 影响：
 - 用户影响：默认无感知；启用 lookup_async 后，调度器响应延迟降低（查找不再串行阻塞），但单请求完成时间可能略有增加（需多一次调度步骤重试）。适用于对延迟敏感的高并发前缀缓存场景。
 - 系统影响：减少调度关键路径的不必要等待，提高整体吞吐。后台线程执行 ZMQ 网络 I/O，对 GPU 计算无干扰。
 - 团队影响：新的配置项需要文档和版本兼容说明；后续若将 LookupKeyClient 移入调度器进程，此异步机制仍然是安全的。
 - 风险标记：默认关闭降低风险，异步清理保证，单线程 executor 可能瓶颈

关联脉络

- PR #45371 [Bugfix][KV Connector] Disable Mooncake TP put-striding when DCP > 1: 修改了相同的 Mooncake store worker 文件 (worker.py)，属于同一套件的基础设施改进。