

PR #46450 完整报告

vllm-project/vllm

[KV Offload] Pass `ScheduleEndContext` to `on_schedule_end` hook

合并时间: 2026-06-30 22:07

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46450>

执行摘要

- 一句话: 为 `on_schedule_end` 传递调度上下文
- 推荐动作: 值得精读。该 PR 展示了在大型推理框架中如何安全地扩展核心钩子参数: 通过引入 `NamedTuple` 显式传递上下文、使用 `Collection` 接口保证迭代安全、全量更新所有实现以维持一致性。其设计讨论 (`dataclass` vs `NamedTuple`、`Iterable` vs `Collection`) 对类似场景有参考价值。

功能与动机

在 KV offload 场景中, 不同调度步骤可能需要针对新请求或抢占请求做出差异化处理 (如立即刷新 store 或调整优先级)。原先 `on_schedule_end()` 不携带上下文, 管理器无法区分当前步骤的调度事件。通过 `ScheduleEndContext` 明确传入 `new_req_ids` 和 `preempted_req_ids`, 使各 tier 管理器能够智能响应特定调度决策。

实现拆解

实现步骤如下:

1. 定义调度上下文数据结构 (`vllm/v1/kv_offload/base.py`): 新增 `ScheduleEndContext` 作为 `NamedTuple`, 包含两个 `Collection[str]` 字段 —— `new_req_ids` 和 `preempted_req_ids`。字段类型选择 `Collection` 以同时支持 list、tuple、set 等可重复消费的集合。
2. 修改核心钩子签名 (`base.py` 中 `OffloadingManager.on_schedule_end()`): 为方法增加 `context: ScheduleEndContext` 参数, 并更新 docstring。
3. 更新二级 Tier 抽象基类 (`tiering/base.py`): `SecondaryTierManager.on_schedule_end()` 同样增加 `context` 参数。
4. 更新所有具体实现: 修改 `tiering/manager.py`、`fs/manager.py`、`obj/manager.py`、`p2p/manager.py` 中的对应 `on_schedule_end` 方法, 使其正确接受并传递 `ScheduleEndContext`。在 `tiering/manager.py` 中还将 `context` 依次传递给所有 `secondary_tiers`。
5. 调度侧构造与传递 (`vllm/distributed/kv_transfer/kv_connector/v1/offloading/scheduler.py`): 在 `OffloadingConnectorScheduler.build_connector_meta()` 中, 根据 `SchedulerOutput` 提供的 `scheduled_new_reqs` 和 `preempted_req_ids` 构造 `ScheduleEndContext` 实例, 然后调用 `self.manager.on_schedule_end(schedule_end_co`

ntext)。

6. 测试配套更新：更新 `tests/v1/kv_offload/tiering/p2p/test_manager.py`、`tests/v1/kv_offload/tiering/test_tiering_offloading.py`、`tests/v1/kv_offload/tiering/test_fs_tier.py`、`tests/v1/kv_offload/tiering/test_obj_tier.py` 等测试文件，适配新的方法签名。

关键文件：

- `vllm/v1/kv_offload/base.py`（模块 离载基类；类别 source；类型 core-logic；符号 `ScheduleEndContext`, `on_schedule_end`）：核心抽象层，定义 `ScheduleEndContext` 并修改 `on_schedule_end` 接口签名，是整个变更的入口。
- `vllm/distributed/kv_transfer/kv_connector/v1/offloading/scheduler.py`（模块 离载调度；类别 source；类型 core-logic）：调度器侧构造 `ScheduleEndContext` 并调用 `on_schedule_end`，是变更的实际使用点。
- `vllm/v1/kv_offload/tiering/manager.py`（模块 分层管理；类别 source；类型 core-logic；符号 `on_schedule_end`）：主要管理器 `CPUPrimaryTierOffloadingManager` 实现 `on_schedule_end`，并在内部将 context 转发给所有二级 tier。
- `vllm/v1/kv_offload/tiering/base.py`（模块 二级离载；类别 source；类型 core-logic；符号 `on_schedule_end`）：`SecondaryTierManager` 抽象基类，定义 `on_schedule_end` 接口，保证所有派生类一致性。
- `vllm/v1/kv_offload/tiering/fs/manager.py`（模块 文件离载；类别 source；类型 core-logic；符号 `on_schedule_end`）：文件系统二级 tier 实现，同步更新 `on_schedule_end` 签名并调用 `flush`。
- `vllm/v1/kv_offload/tiering/obj/manager.py`（模块 对象离载；类别 source；类型 core-logic；符号 `on_schedule_end`）：对象存储二级 tier 实现，同步更新 `on_schedule_end` 签名并调用 `flush`。
- `vllm/v1/kv_offload/tiering/p2p/manager.py`（模块 点对点离载；类别 source；类型 core-logic；符号 `on_schedule_end`）：点对点二级 tier 实现，同步更新 `on_schedule_end` 签名。
- `tests/v1/kv_offload/tiering/p2p/test_manager.py`（模块 P2P 测试；类别 test；类型 test-coverage）：P2P 管理器测试，更新测试代码适配新签名，验证基本功能不退化。
- `tests/v1/kv_offload/tiering/test_tiering_offloading.py`（模块 分层测试；类别 test；类型 test-coverage）：分层 offloading 管理器测试，适配新签名，保证级联转发逻辑正确。
- `tests/v1/kv_offload/tiering/test_fs_tier.py`（模块 文件离载测试；类别 test；类型 test-coverage）：文件系统 tier 测试，适配新签名。
- `tests/v1/kv_offload/tiering/test_obj_tier.py`（模块 对象离载测试；类别 test；类型 test-coverage）：对象存储 tier 测试，适配新签名。

关键符号：`on_schedule_end`, `ScheduleEndContext`, `build_connector_meta`

关键源码片段

`vllm/v1/kv_offload/base.py`

核心抽象层，定义 `ScheduleEndContext` 并修改 `on_schedule_end` 接口签名，是整个变更的入口。

```
# SPDX-License-Identifier: Apache-2.0
# SPDX-FileCopyrightText: Copyright contributors to the vLLM project

from typing import NamedTuple
from collections.abc import Collection

class ScheduleEndContext(NamedTuple):
    # Per-step scheduling info passed to on_schedule_end()
    # 包含本轮调度中新请求和抢占请求的 ID 集合 .
    # 本轮首次调度的请求 ID (request IDs scheduled for the first time this step).
    new_req_ids: Collection[str]
    # 本轮被抢占的请求 ID (request IDs preempted this step).
    preempted_req_ids: Collection[str]
```

```
class OffloadingManager(ABC):

    def on_schedule_end(self, context: ScheduleEndContext) -> None:
        # Called once at the end of each scheduler step.
        # Managers may override this to flush deferred work accumulated
        # during the step (e.g., batched promotions).
        return
```

[vllm/distributed/kv_transfer/kv_connector/v1/offloading/scheduler.py](https://github.com/vllm-project/vllm/blob/main/vllm/distributed/kv_transfer/kv_connector/v1/offloading/scheduler.py)

调度器侧构造 `ScheduleEndContext` 并调用 `on_schedule_end`，是变更的实际使用点。

```
def build_connector_meta(
    self, scheduler_output: SchedulerOutput
) -> KVConnectorMetadata:
    self._update_req_states(scheduler_output)

    # 构造 ScheduleEndContext, 从 scheduler_output 中提取新请求 ID 和抢占请求 ID.
    schedule_end_context = ScheduleEndContext(
        new_req_ids=[
            req.req_id for req in scheduler_output.scheduled_new_reqs
        ],
        preempted_req_ids=scheduler_output.preempted_req_ids or (),
    )
    self.manager.on_schedule_end(schedule_end_context)

    # 处理被抢占请求的 job 刷出
    for req_id in scheduler_output.preempted_req_ids or ():
        req_status = self._req_status.get(req_id)
        if req_status is None or not req_status.transfer_jobs:
            continue
        any_jid = next(iter(req_status.transfer_jobs))
```

```
assert self._jobs[any_jid].is_store
self._current_batch_jobs_to_flush.update(req_status.transfer_jobs)
```

... 后续逻辑不变 ...

评论区精华

Review 中的核心讨论包括：

- 设计选择：orozery 提议将 `ScheduleEndContext` 从 `dataclass` 改为 `NamedTuple`, ronensc 采纳 (commit c283e7eb)。
- 类型安全：orozery 担心 `Iterable` 在多 tier 遍历时会被耗尽，建议使用 `Collection` 或 `Sequence`；ronensc 指出 `preempted_req_ids` 来源是 `set`，与 `Sequence` 不兼容，最终采用 `Collection`。
- 性能微调：关于 `new_req_ids` 应使用 `list` 还是 `tuple`，ronensc 给出 `microbenchmark` 数据，证明 `list` 构造开销更小，且单步请求数量有限，最终保留 `list`。
- 合并冲突修复：orozery 发现冲突解决时误删了 `from enum import auto`，ronensc 确认并提交修复。
 - `ScheduleEndContext` 类型：`dataclass` vs `NamedTuple` (design): 使用 `NamedTuple`。
 - 字段类型：`Iterable` vs `Collection` vs `Sequence` (design): 使用 `Collection[str]` 兼容 `set/list/tuple`。
 - 数据结构性能：`list` vs `tuple` (performance): 使用 `list` 构造 `new_req_ids`。
 - 合并冲突导致 `auto` 导入丢失 (other): 恢复 `import auto`。

风险与影响

- 风险：
 1. 接口兼容性风险：所有继承 `OffloadingManager` 或 `SecondaryTierManager` 的自定义子类必须同步更新 `on_schedule_end` 签名，否则运行时触发 `TypeError`。内部实现已全部更新，但仓库外部署可能遗漏。
 2. 测试覆盖不足：现有测试仅验证签名正确性，未充分验证 `ScheduleEndContext` 内容在各管理器中的实际消费逻辑，存在回归盲点。
 3. 性能风险：每步调度构造 `ScheduleEndContext` 对象和列表，在高并发下可能产生短暂内存分配，但相对整体 offload 开销可忽略。
- 影响：
 - 对用户：KV offload 功能用户无直接行为变化，但为未来更智能的缓存策略提供了原料。
 - 对系统：offload 管理器现可感知新请求和抢占，有望提升内存利用率和降低延迟。
 - 对团队：所有 offload 模块统一更新，降低后续二次开发成本。
 - 风险标记：接口变更，测试覆盖不足，自定义实现兼容性

关联脉络

- 暂无明显关联 PR