

PR #29429 完整报告

sgl-project/sglang

Let the presence of req.kv indicate the existence of owned kv resources

合并时间: 2026-07-15 14:47

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29429>

执行摘要

- 一句话: 用 req.kv 存在性表示 KV 资源是否已分配
- 推荐动作: 值得精读。该 PR 是 SGLang KV 生命周期解耦系列的重要基石, 展示了如何用类型系统和对象存在性代替代理字段管理资源。阅读时可以重点关注 `schedule_batch.py` 中 Req 的初始化、`reset_for_retract` 中的断言以及 `mem_cache/common.py` 中 `release_kv_cache` 的结尾变更。

功能与动机

原代码中 req.kv 总是存在一个占位对象, 导致无法区分“未分配 KV”和“KV 已分配但 kv_allocated_len=0”。该 PR 通过让 req.kv 的存在性直接表示资源所有权, 使 allocate/free 路径只在实际分配 / 释放 KV 时操作 req.kv, 为后续进一步解耦做准备。

实现拆解

1. 变更字段默认值: 在 Req.__init__ (`schedule_batch.py`) 中, 将 self.kv: Optional[ReqKvInfo] = None 替代原来的 ReqKvInfo(...), 消除零占位对象。
2. 删除占位工厂函数: 在 `streaming_session.py` 中删除 `_new_kv()` 函数, SessionSlot.kv 字段也改为 Optional[ReqKvInfo] = None; 在 `save_from_req` 和 `try_cache_finished_req` 中增加 req.kv = None 以在所有权转移后清除引用。
3. 在分配点创建 ReqKvInfo: DecodeWorker._pre_alloc (`disaggregation/decode.py`) 中, 当 req.kv is None 时才创建 ReqKvInfo, 否则只更新 kv_allocated_len; `prepare_for_extend` (`schedule_batch.py`) 中类似处理。
4. 在释放点置 None: `release_kv_cache` (`mem_cache/common.py`) 末尾增加 req.kv = None; `free_swa_out_of_window_slots` 开头增加 if req.kv is None: return 保护; `scheduler_pp_mixin.py` 中 `profile_and_init_predictor` 中释放时也置 None。
5. 适配不变检查: `invariant_checker.py` 中在遍历 reqs 时跳过 req.kv is None 的请求。
6. 测试文件: `test_unified_radix_cache_unittest.py` 调整测试断言以适配新语义。

关键文件:

- `python/sglang/srt/managers/schedule_batch.py` (模块 调度批次; 类别 source; 类型 core-logic; 符号 Req.init, Req.reset_for_retract, Req.prepare_for_extend) : Req 类的 kv 字段定义和生命周期管理的核心变更所在

- python/sglang/srt/session/streaming_session.py (模块 流式会话; 类别 source; 类型 core-logic; 符号 `_new_kv` (removed), `SessionSlot.init`, `SessionSlot.save_from_req`, `StreamingSession.try_cache_finished_req`) : `SessionSlot` 的 kv 字段及所有权传递逻辑
- python/sglang/srt/disaggregation/decode.py (模块 解码分配; 类别 source; 类型 dependency-wiring; 符号 `DecodeWorker._pre_alloc`) : 解码时 KV 预分配路径创建 `ReqKvInfo`
- python/sglang/srt/mem_cache/common.py (模块 缓存层; 类别 source; 类型 core-logic; 符号 `free_swa_out_of_window_slots`, `release_kv_cache`) : KV 缓存释放时置 `None`, SWA 滑动窗口释放保护
- python/sglang/srt/managers/scheduler_components/invariant_checker.py (模块 不变检查; 类别 source; 类型 core-logic; 符号 `_add_owner` (loop integration)) : 不变检查适配 `req.kv` 可能为 `None`
- python/sglang/srt/managers/scheduler_pp_mixin.py (模块 流水线调度; 类别 source; 类型 core-logic; 符号 `profile_and_init_predictor`) : 流水线调度 profiling 释放时置 `None`

关键符号: `Req.init`, `Req.reset_for_retract`, `Req.prepare_for_extend`, `SessionSlot.init`, `SessionSlot.save_from_req`, `StreamingSession.try_cache_finished_req`, `DecodeWorker._pre_alloc`, `free_swa_out_of_window_slots`, `release_kv_cache`, `profile_and_init_predictor`

关键源码片段

python/sglang/srt/managers/schedule_batch.py

`Req` 类的 kv 字段定义和生命周期管理的核心变更所在

file: python/sglang/srt/managers/schedule_batch.py

```
class Req:
    def __init__(self, ...):
        # ...
        # 之前: self.kv: ReqKvInfo = ReqKvInfo(kv_allocated_len=0, swa_evicted_seqlen=0)
        # 现在: 初始化为 None, 真正分配时才会创建 ReqKvInfo 对象
        self.kv_committed_len = 0
        self.kv: Optional[ReqKvInfo] = None
        # ...

    def reset_for_retract(self):
        # ...
        # 调用 reset_for_retract 之前, kv 应已在 release 路径中被置为 None
        assert self.kv is None, "expect it is already released"
        self.kv_committed_len = 0
        # 原先还重置 self.kv.kv_allocated_len = 0 和 self.kv.swa_evicted_seqlen = 0, 现在不再需要
        # ...
```

python/sglang/srt/session/streaming_session.py

`SessionSlot` 的 kv 字段及所有权传递逻辑

```
# file: python/sglang/srt/session/streaming_session.py

# 之前存在 _new_kv 工厂函数，现已删除
# def _new_kv() -> ReqKvInfo:
# from sglang.srt.managers.schedule_batch import ReqKvInfo
# return ReqKvInfo(kv_allocated_len=0, swa_evicted_seqlen=0)

@dataclass
class SessionSlot:
    # ...
    # KV pool state (None means no KV is currently held by this slot)
    req_pool_idx: Optional[int] = None
    kv_committed_len: int = 0
    kv: Optional[ReqKvInfo] = None # 原先为 field(default_factory=_new_kv)
    # ...

    def save_from_req(self, req: Req, is_first: bool):
        # ...
        # 从 req 拷贝 kv 状态后，将 req.kv 置为 None 以标记所有权转移
        req.req_pool_idx = None
        req.kv = None # 新增行
        req.mamba_pool_idx = None
        # ...
```

评论区精华

Review 由 Gemini Code Assist 自动生成，提出两点建议：

- 在 `reset_for_retract` 中的 `assert self.kv is None` 可能在意外状态时造成服务器崩溃，建议改为安全日志并清理。
- 在 `_pre_alloc` 中的 `import ReqKvInfo` 在条件内部会导致热路径开销，建议移至函数顶部。两条建议均未被采纳，最终合并保留了原有代码。
- `assert` 在 `reset_for_retract` 中可能引起崩溃 (correctness): 未采纳，作者保留了 `assert` 以在开发阶段捕获违反契约的情况。
- `import ReqKvInfo` 在热路径条件内部 (performance): 未采纳，作者保留在条件内部以避免循环依赖（可能）。

风险与影响

- 风险：主要风险在于遗漏某些代码路径仍假设 `req.kv` 永不 `None`，可能引发 `AttributeError`。但作者已逐一检查并修复了所有相关引用点（8 个文件），并在 `free_swa_out_of_window_slots` 和 `invariant_checker` 中添加 `None` 保护。`assert` 在生产环境中可能被禁用（-O），但默认启用，若意外触发将导致进程退出，但概率极低。整体风险可控。
- 影响：影响范围包括所有涉及 KV 资源管理的模块：调度批次、流式会话、前缀缓存、分解解码、不变检查以及流水线调度。由于语义变更为等价变换（行为不变），对用户透明；对后续开发者则需要理解 `req.kv is None` 的含义，不能依赖其始终存在。团队需要确保未来

新增的代码也遵循此契约。

- 风险标记：核心路径变更，assert 潜在崩溃风险，热路径 import 开销未优化

关联脉络

- PR #29430 Fix abusing presence of req.req_pool_idx to indicate the presence of req.kv resources: 同一解耦链条中的后续修复，直接依赖本 PR 的语义变更
- PR #29431 Lightweight extract allocation logic from mem_cache/common.py to more clearly show nearly parallel variants: 基于本 PR 的 req.kv 语义，进一步提取分配逻辑
- PR #29432 Fix bookkeeping fields not encapsulated with real allocations in normal alloc, PD pre-alloc, DFlash and EAGLE: 进一步封装 KV 记账到分配函数，依赖本 PR 引入的 req.kv 存在性语义