

PR #36958 完整报告

sgl-project/sglang

[mem_cache] Keep `req.kv` non-optional and key KV ownership on `req\_pool\_idx`

合并时间: 2026-08-29 14:47

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36958>

执行摘要

- 一句话: Req.kv 常驻化, KV 归属统一由 req_pool_idx 判定
- 推荐动作: 值得精读。这是 SGLang mem_cache KV 所有权重构系列的开篇 (分支名 lsyin/kv-ownership-pr1), is_holding_kv 单一谓词 + eager 对象 + 清零释放的组合是后续 #37094、#37108、#37164 的阅读前提。建议重点理解三处: ReqKvInfo.is_released/mark_released 的契约、release_kv_cache 收紧后的断言、以及 streaming_session.py 中 slot 与 req 之间的所有权转移方式。

功能与动机

PR body 明确指出: Keep `req.kv` on the `Req` for its whole lifetime (zeroed via `mark_released()` instead of set to `None`) and make `req_pool_idx is not None` the single "holds KV" predicate。row 与 KV 簿记本来就同时分配、同时释放, 三个 `if req.kv is None` 分配分支说明对象创建被分散在 `allocation.py`、`decode.py` 等多处, eager 化后可以全部折叠, 并把生命周期断言从两个平行 Optional 状态收敛为互斥一致的不变量。

实现拆解

1. `ReqKvInfo` eager 化与生命周期方法: 在 `python/sglang/srt/managers/schedule_batch.py` 中, `ReqKvInfo` 两个字段 (`kv_allocated_len`、`swa_evicted_seqlen`) 获得默认值 0, 新增 `is_released` 属性 (两字段同时为 0) 与 `mark_released()` 方法 (清零两字段); `Req.__init__` 中 `self.kv` 由 `Optional[ReqKvInfo] = None` 改为 `ReqKvInfo()`; 新增 `Req.is_holding_kv` 属性 (`return self.req_pool_idx is not None`); `reset_for_retract` 中断言由 `assert self.kv is None` 改为 `assert not self.is_holding_kv`。
2. 谓词替换: 所有 `req.kv is None` 判断替换为 `req.is_holding_kv` 或 `not req.is_holding_kv`。涉及: `mem_cache/common.py` 的 `free_swa_out_of_window_slots` 与 `release_kv_cache`、`schedule_batch.py` 的 `maybe_evict_swa`、`managers/scheduler_components/invariant_checker.py` 的 `_get_total_uncached_sizes` 与 `_add_owner`、`disaggregation/prefill.py` 的 `handle_bootstrap_failure`、`managers/scheduler_pp_mixin.py` 的 PP 动态块 `release` 路径。
3. 折叠分配分支: `mem_cache/allocation.py` 的 `alloc_for_extend` 与 `_alloc_extend_loc_with_kv_reuse`、`disaggregation/decode.py` 的 `alloc_for_decode_prealloc_hispase` 与 `alloc_for_decode_prealloc` 中, 三处 `if req.kv is None: req.kv = ReqKvInfo(...)` 分支全部删除, 变为直接赋值 `req.kv.kv_allocated_len`

= fill_len / seq_len, 同时移除相应局部 ReqKvInfo 导入。

4. 释放路径统一 mark_released(): mem_cache/common.py 的 release_kv_cache 中, 生命周期断言由 (req.req_pool_idx is None) == (req.kv is None) 收紧为 (not req.is_holding_kv) == req.kv.is_released, 末尾 req.kv = None 改为 req.kv.mark_released(); managers/scheduler_pp_mixin.py、disaggregation/decode_kvcache_offload_manager.py 的 _release_finished_req 同样改用 mark_released(); session/streaming_session.py 的 save_from_req 与 try_cache_finished_req 在所有权转移给 slot 时将 req.kv = None 改为 req.kv = ReqKvInfo(), 同时 SessionSlot.kv 改为 field(default_factory=ReqKvInfo)、SessionSlot.is_holding_kv 改为基于 req_pool_idx。
5. 测试与辅助适配: 8 个测试文件 (test_unified_radix_cache_unittest.py、test_dllm_fdfo_kv_reuse.py、test_specv2_kvcache_offloading.py、test_unified_radix_cache_bench.py、test_hispase_allocator.py、test_kv_page_invariants.py、test_swa_eviction_boundary.py, 以及 python/sglang/test/scripted_runtime/req_handle.py) 适配 eager kv 语义, 移除对 kv=None 的假设。配套变更的关键在于: 断言从“两个 None 平行”转为“谓词与清零互斥一致”, 任何遗漏 mark_released() 的路径都会被立即暴露。

关键文件:

- python/sglang/srt/managers/schedule_batch.py (模块 调度器; 类别 source; 类型 core-logic; 符号 is_released, mark_released, is_holding_kv, ReqKvInfo): 核心数据模型变更入口: ReqKvInfo 常驻化、is_holding_kv 单一谓词、断言收紧都在此定义
- python/sglang/srt/mem_cache/common.py (模块 缓存管理; 类别 source; 类型 core-logic; 符号 release_kv_cache, free_swa_out_of_window_slots, mark_released): 所有请求结束时的 KV 释放主路径, 生命周期不变式与 mark_released 语义在此落地
- python/sglang/srt/session/streaming_session.py (模块 流式会话; 类别 source; 类型 dependency-wiring; 符号 SessionSlot, save_from_req, find_active_slot, is_holding_kv): 流式会话 slot 与 req 间 KV 所有权转移的重构关键, slot 状态与 req 状态同步调整
- python/sglang/srt/mem_cache/allocation.py (模块 KV 分配; 类别 source; 类型 dependency-wiring; 符号 alloc_for_extend, _alloc_extend_loc_with_kv_reuse): 展示分支折叠收益: 三处 kv 空判断中最典型的分配入口
- python/sglang/srt/disaggregation/decode.py (模块 PD 分离; 类别 source; 类型 core-logic; 符号 alloc_for_decode_prealloc, alloc_for_decode_prealloc_hispase): PD 分离场景下 decode 预分配路径的分支折叠与 ReqKvInfo 导入清理
- test/registered/unit/mem_cache/test_unified_radix_cache_unittest.py (模块 单元测试; 类别 test; 类型 test-coverage): 变更覆盖最广的测试适配文件, 验证 eager kv 语义下统一 radix cache 行为不变

关键符号: ReqKvInfo.is_released, ReqKvInfo.mark_released, Req.is_holding_kv, Req.reset_for_retract, SessionSlot.is_holding_kv, SessionSlot.save_from_req, release_kv_cache, free_swa_out_of_window_slots, alloc_for_decode_prealloc, alloc_for_decode_prealloc_hispase, free_member_rows, handle_bootstrap_failure, _release_finished_req, _get_total_uncached_sizes

关键源码片段

python/sglang/srt/managers/schedule_batch.py

核心数据模型变更入口：ReqKvInfo 常驻化、is_holding_kv 单一谓词、断言收紧都在此定义

```
@dataclasses.dataclass(slots=True, kw_only=True)
class ReqKvInfo:
    # Device KV a request holds outside the prefix cache.
    # 对象在 Req 整个生命周期内常驻；释放时用 mark_released() 清零而不是置 None
    kv_allocated_len: int = 0
    swa_evicted_seqlen: int = 0

    @property
    def is_released(self) -> bool:
        # 两个字段同时归零即视为已释放，作为释放断言的一侧
        return self.kv_allocated_len == 0 and self.swa_evicted_seqlen == 0

    def mark_released(self) -> None:
        # 清零而不是删除对象，后续分配路径直接覆盖字段
        self.kv_allocated_len = 0
        self.swa_evicted_seqlen = 0

class Req(ReqDlrmMixin):
    def __init__(self, ...):
        ...
        # For req-level memory management
        self.kv_committed_len = 0
        # eager 创建：三个 if req.kv is None 分配分支得以折叠
        self.kv = ReqKvInfo()
        ...

    @property
    def is_holding_kv(self) -> bool:
        # KV 所有权判定的单一事实源：req_pool_idx 是否为 None
        return self.req_pool_idx is not None
```

python/sglang/srt/mem_cache/common.py

所有请求结束时的 KV 释放主路径，生命周期不变式与 mark_released 语义在此落地

```
def release_kv_cache(req: Req, tree_cache: BasePrefixCache, is_insert: bool = True):
    # 生命周期不变量：不持有 KV (req_pool_idx 为空) 当且仅当 kv 已清零
    assert (not req.is_holding_kv) == req.kv.is_released

    # MambaRadixCache 可能先分配 mamba state 再分配 KV cache
    if not req.is_holding_kv:
        assert (
            tree_cache.supports_mamba()
        ), "Only MambaRadixCache allow freeing before alloc"
```

```

    if req.mamba_pool_idx is not None:
        tree_cache.req_to_token_pool.mamba_allocator.free(
            req.mamba_pool_idx.unsqueeze(-1)
        )
        req.mamba_pool_idx = None
    return

effective_kv_committed_len = req.effective_kv_committed_len()
tree_cache.cache_finished_req(
    req,
    is_insert=is_insert and not getattr(req, "skip_radix_cache_insert", False),
    kv_len_to_handle=effective_kv_committed_len,
)

# StreamingSession.cache_finished_req 内部处理 speculative tail trim 后
# 会设置 req_pool_idx 为 None, 因此这里再次校验不变量
assert (not req.is_holding_kv) == req.kv.is_released
if not req.is_holding_kv:
    return

start_p, end_p = effective_kv_committed_len, req.kv.kv_allocated_len
_release_overallocated_kv_indices(req, start_p, end_p, tree_cache)

# 若前缀缓存不管理 mamba 状态, 则在此释放
if isinstance(tree_cache.req_to_token_pool, HybridReqToTokenPool) and (
    not tree_cache.supports_mamba()
):
    assert (
        req.mamba_pool_idx is not None
    ), "mamba state is freed while the tree cache does not manage mamba states"
    tree_cache.req_to_token_pool.free_mamba_cache(req)

tree_cache.req_to_token_pool.free(req)
# 清零而不是置 None: ReqKvInfo 保留, 下次分配直接写字段
req.kv.mark_released()

```

评论区精华

本 PR 无任何 review 评论 (comments_count=0、review_comments_count=0) , 作者直接合并。可以从 commit 演进还原设计意图: [eager ReqKvInfo; presence via req_pool_idx](#) 确立核心方案, [fix test fakes for eager kv; simplify dllm reuse check](#) 展示分支折叠的收益, 两次 merge main 保证与主干同步。

- 暂无高价值评论线程

风险与影响

- 风险: 风险:

- `release_kv_cache` 与 `_release_finished_req` 是每个请求结束的必经路径，断言收紧后，任何“设置了 `req_pool_idx = None` 但漏调 `mark_released()`”的路径会直接触发 `AssertionError`。这是刻意暴露存量缺陷，但也意味着仓库内其他未被本 PR 覆盖的 `req.kv = None` 直接赋值点（例如某些硬件后端或实验模块）可能立即暴露。
- `ReqKvInfo` 常驻使“释放后仍访问 `kv` 字段”从 `AttributeError` 变成读到零点 / 旧值，可能掩盖访问已释放状态的逻辑错误；不过 `mark_released()` 会把两字段归零，误读会得到 0。
- `SessionSlot` 常驻一个 `ReqKvInfo`，`slot` 数量多时存在微量内存增加，可忽略。
- 涉及 10 个源文件、横跨调度、缓存、PD 分离、beam search、PP 多条路径，虽有 `run-ci` 全量验证，但边缘路径（如 DSV4-NPU、Mamba、hi sparse 组合）覆盖仍可能不足。
- 影响：对用户无直接行为变化（纯内部重构）。对代码库的收益是“持有 KV”的判定从两个平行 `Optional` 收敛为单一谓词，后续把 `req_pool_idx`、`mamba state`、`retraction_backup` 等收进 `ReqKvInfo` 的系列重构（#37094、#37108、#37164）均建立在这一数据模型之上。对所有接触 `Req/SessionSlot` 的开发者：新增的 `is_holding_kv` 语义必须遵守，释放必须走 `mark_released()`。
- 风险标记：核心调度路径变更，跨模块联动重构，断言收紧暴露存量缺陷，释放路径遗漏 `mark_released` 风险

关联脉络

- PR #37094 [mem_cache] Move `req_pool_idx` into `ReqKvInfo`: 本 PR 确立 `is_holding_kv` 单一谓词后，37094 将 `req_pool_idx` 收进 `ReqKvInfo`，是同一所有权收拢系列的下一步，直接依赖本 PR 的数据模型。
- PR #37108 [mem_cache] Share one `ReqKvInfo` between a streaming session slot and its request: 本 PR 让 `ReqKvInfo` 常驻并支持清零复用，37108 才得以让 `slot` 与 `req` 共享同一个 `ReqKvInfo`。
- PR #37164 [mem_cache] Move `mamba state` and `retraction_backup` into `ReqKvInfo`: 继续把 `mamba state`、`retraction_backup` 收进 `ReqKvInfo`，涉及本 PR 修改的 `schedule_batch.py`、`streaming_session.py` 等文件。