

PR #27402 完整报告

sgl-project/sglang

[sgl] proactively release out-of-window SWA slots after chunked prefill

合并时间: 2026-06-12 14:17

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/27402>

执行摘要

- 一句话: 主动释放 SWA 窗口外 KV 槽位, 优化长上下文内存使用
- 推荐动作: 值得精读, 尤其是组件级 hook 设计和页面边界保护逻辑 (page_size 减一策略), 以及如何通过环境变量平滑引入行为变更。

功能与动机

在长上下文运行中, 未完成的 prefill 请求中的 SWA KV 槽位即使已滑出窗口仍被持续占用, 导致 SWA 内存使用不受控。PR body 明确提出“bounding SWA pool usage for long-context runs”。

实现拆解

1. 添加基类 hook: 在 TreeComponent (tree_component.py) 中新增 free_out_of_window_slots 默认方法 (pass), 供子类按需重写。
2. SWA 组件实现: SWAComponent (swa_component.py) 实现该方法, 调用通用函数 free_swa_out_of_window_slots, 计算应释放的槽位范围 (pre_len - sliding_window_size - page_size) 并调用 token_to_kv_pool_allocator.free_swa。
3. 驱动点注入: 在 UnifiedRadixCache.cache_unfinished_req (unified_radix_cache.py) 中, 当环境变量启用时, 遍历所有组件并调用 free_out_of_window_slots, 结果记录到 insert_params.swa_evicted_seqlen。
4. 调度层重构: 将 ScheduleBatch._evict_swa (schedule_batch.py) 中的内联释放逻辑替换为调用 free_swa_out_of_window_slots, 消除代码重复。
5. 测试覆盖: 在 test_unified_radix_cache_unittest.py 中添加 test_swa_eager_eviction_on_unfinished_req 和 test_swa_eager_eviction_noop_when_within_window, 验证释放行为和窗口内无操作。
6. 配置: 在 environ.py 中新增环境变量 SGLANG_OPT_UNIFIED_CACHE_FREE_OUT_OF_WINDOW_SLOTS, 默认关闭。

关键文件:

- 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): 新增核心函数 free_swa_out_of_window_slots, 包含页面边界保护和槽位释放逻辑, 是整个功能的计算核心。

- python/sglang/srt/mem_cache/unified_cache_components/swa_component.py (模块 缓存层; 类别 source; 类型 core-logic; 符号 free_out_of_window_slots) : 实现 free_out_of_window_slots hook , 将 SWA 组件特定的参数传递给通用函数, 并更新 insert_params。
- python/sglang/srt/mem_cache/unified_radix_cache.py (模块 缓存层; 类别 source; 类型 dependency-wiring) : 在 cache_unfinished_req 中根据环境变量驱动组件循环, 是 hook 的调用入口。
- python/sglang/srt/managers/schedule_batch.py (模块 调度器; 类别 source; 类型 core-logic; 符号 _evict_swa) : 将 _evict_swa 内联逻辑重构为调用通用函数 free_swa_out_of_window_slots, 消除重复代码。
- python/sglang/srt/mem_cache/unified_cache_components/tree_component.py (模块 缓存层; 类别 source; 类型 core-logic; 符号 free_out_of_window_slots) : 基类 TreeComponent 添加 free_out_of_window_slots 空方法, 定义了 hook 接口。
- test/registered/unit/mem_cache/test_unified_radix_cache_unittest.py (模块 测试; 类别 test; 类型 test-coverage; 符号 test_swa_eager_eviction_on_unfinished_req, test_swa_eager_eviction_noop_when_within_window) : 新增两个测试用例覆盖主动释放和窗口内无操作, 验证逻辑正确性。

关键符号: free_swa_out_of_window_slots, SWAComponent.free_out_of_window_slots, UnifiedRadixCache.cache_unfinished_req, ScheduleBatch._evict_swa

关键源码片段

python/sglang/srt/mem_cache/common.py

新增核心函数 `free_swa_out_of_window_slots`, 包含页面边界保护和槽位释放逻辑, 是整个功能的计算核心。

```
# python/sglang/srt/mem_cache/common.py
```

```
def free_swa_out_of_window_slots(
    req: Req,
    pre_len: int,
    *,
    sliding_window_size: int,
    page_size: int,
    req_to_token_pool: ReqToTokenPool,
    token_to_kv_pool_allocator: BaseTokenToKVPoolAllocator,
) -> None:
    from sglang.srt.environ import envs

    # cache_protected_len 必须是 page_size 对齐的
    assert req.cache_protected_len % page_size == 0, "cache_protected_len must be page aligned"
    req.swa_evicted_seqlen = max(req.swa_evicted_seqlen, req.cache_protected_len)

    # 减去一页 margin, 避免释放达到 radix tree 插入边界, 防止 tombstones 导致内存泄漏
```

```

if envs.SGLANG_OPT_SWA_EVICT_DROP_PAGE_MARGIN.get():
    evict_threshold = pre_len - sliding_window_size
else:
    evict_threshold = pre_len - sliding_window_size - page_size

new_swa_evicted_seqlen = max(req.swa_evicted_seqlen, evict_threshold)

# 按页对齐 evict_seqlen
if page_size > 1:
    new_swa_evicted_seqlen = (new_swa_evicted_seqlen // page_size) * page_size

if new_swa_evicted_seqlen > req.swa_evicted_seqlen:
    free_slots = req_to_token_pool.req_to_token[
        req.req_pool_idx, req.swa_evicted_seqlen : new_swa_evicted_seqlen
    ]
    token_to_kv_pool_allocator.free_swa(free_slots)
    req.swa_evicted_seqlen = new_swa_evicted_seqlen

```

python/sglang/srt/mem_cache/unified_cache_components/swa_component.py

实现 `free_out_of_window_slots` hook，将 SWA 组件特定的参数传递给通用函数，并更新 `insert_params`。

```
# python/sglang/srt/mem_cache/unified_cache_components/swa_component.py
```

```
from sglang.srt.mem_cache.common import free_swa_out_of_window_slots
```

```

class SWAComponent(TreeComponent):
    # ... 其他代码 ...

    def free_out_of_window_slots(
        self, req: Req, pre_len: int, insert_params: InsertParams
    ) -> None:
        if self.sliding_window_size is not None:
            free_swa_out_of_window_slots(
                req,
                pre_len,
                sliding_window_size=self.sliding_window_size,
                page_size=self.cache.page_size,
                req_to_token_pool=self.cache.req_to_token_pool,
                token_to_kv_pool_allocator=self.cache.token_to_kv_pool_allocator,
            )
            # 记录 evicted_seqlen 到 insert_params，后续插入时使用
            insert_params.swa_evicted_seqlen = req.swa_evicted_seqlen

```

评论区精华

讨论 1：环境变量 vs CLI 参数 ispobock 建议保持为环境变量，因为该功能目前只对 unified tree 生效，bixue2010 同意并修改。

讨论 2: hook 是否应对所有组件调用 ispobock 询问是否只需要 SWA 组件, bixue2010 认为应作为通用 hook, 其他组件 (如 Mamba) 未来可按需实现。结论: 保留对所有组件的循环调用, 目前 SWA 实现, 其余 no-op。

- 是否应使用 CLI 参数而非环境变量 (design): 改为环境变量
SGLANG_OPT_UNIFIED_CACHE_FREE_OUT_OF_WINDOW_SLOTS。
- hook 是否应对所有组件调用 (design): 保留对所有组件循环调用, 目前 SWA 实现释放逻辑, 其余组件 no-op。

风险与影响

- 风险: 涉及缓存管理逻辑变更, 主要风险在于页面边界和对齐条件的正确处理。
free_swa_out_of_window_slots 中关于 cache_protected_len 必须 page-aligned 的断言, 以及 page_size>1 时的对齐逻辑, 若假设不成立可能导致错误释放或内存泄漏。但通过单元测试和环境变量门控 (默认关闭), 对现有用户无影响。
- 影响: 对使用 SWA 的模型 (如 DeepSeek 等) 有正面影响, 减少无效 KV 占用, 提升长上下文时的批处理能力。非 SWA 模型无影响。启用环境变量后, 每个 chunked prefill 完成后立即释放窗口外槽位, 可能略微增加计算开销, 但内存收益显著。
- 风险标记: 核心缓存路径变更, 受环境变量控制, 需测试覆盖

关联脉络

- 暂无明显关联 PR