

PR #37091 完整报告

sgl-project/sglang

[Unified Cache][1/N]: Support cache contract for external linker

合并时间: 2026-08-30 22:24

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/37091>

执行摘要

- 一句话: 为外部缓存链接器定义传输与加载契约, 并跟踪插入采用的 KV 范围
- 推荐动作: 建议精读。该 PR 展示了如何在不污染既有路径的前提下, 通过阶段枚举和组件钩子为跨节点 KV 缓存定义清晰契约, 值得学习其“先契约后实现”的拆分策略。关注重点: record_adopted_range 的区间合并语义、external_cache_stored 与 HiCache 备份的互斥设计, 以及 SWA 的 TRAILING_PAGES 窗口对齐方式。

功能与动机

PR body 明确说明这是 external linker 系列的第一个 PR, 从原先的完整实现 #35687 中拆分出来, 目的是引入组件级传输和加载生命周期契约, 并在 UnifiedTree 插入时记录被 Full/SWA 采用的范围, 以便后续去重远程加载。由于只动缓存侧契约, linker 接线与后端实现留到后续 PR, 这样可以独立评审缓存侧的正确性。

实现拆解

实现按“契约定义、组件实现、树状态集成、测试配套”四步展开:

1. 定义外部链接器阶段契约: 在 tree_component.py 中新增 LinkerTransferPhase (LOOKUP / LOAD / OFFLOAD) 和 ExternalLinkerLoadPhase (PREPARE / COMMIT / ABORT) 两个枚举, 并在 TreeComponent 基类增加默认钩子 build_external_linker_transfer 和 update_external_linker_load, 默认分别返回 None 与原样透传, 保证未接入链路时行为不变。
2. 按组件实现传输构造:
 - full_component.py 新增 _full_allocator() 统一选择 full-attention 池; build_external_linker_transfer 在 OFFLOAD 时导出整段设备 KV 索引与逐页哈希, LOOKUP 只带 keys, LOAD 时先按页数计算不足并驱逐, 再分配设备槽位填入 PoolTransfer.device_indices; update_external_linker_load 在 ABORT 阶段释放预留槽位。
 - swa_component.py 更复杂: OFFLOAD 只导出滑动窗口尾部若干页并标记 PoolHitPolicy.TRAILING_PAGES; LOAD 分配 swa_attn_allocator 的槽位; PREPARE 阶段将 full 与 SWA 槽位建立 set_full_to_swa_mapping, 并按 prefix_len 推算 swa_evicted_seqlen 写回 req.kv; COMMIT 阶段用最终落定的 canonical full 索引重新映射。

- `mamba_component.py` 显式 `raise AssertionError`, 声明暂不支持外部链接器模式, 避免静默错误。
3. 为 `UnifiedTree` 增加外部缓存状态与采用范围记录: `unified_tree_core.py` 中 `UnifiedTreeNode` 新增 `external_cache_stored` 标志, `UnifiedTreeCore` 新增 `enable_external_cache_linker` 开关 (默认 `False`) ; `_inc_hit_count_and_check` 在开启外部链接器时改用 `external_cache_stored` 判断是否触发 `write-back`, `_add_new_node` 在开启时也计算 `hash_value`, `_split_node` 传播该标志; `_build_backup_kv_action` 将 `external_cache_stored` 的祖先视为无需再备份。同时在 `InsertResult` 中新增 `adopted_ranges` 与 `record_adopted_range()`, 在 `insert walk` 的 `unevict`、`overlap`、`commit` 三个位置按组件记录实际吸收 KV 的区间, 供后续去重远端加载。
 4. 配套调整与测试: `hicache_storage.py` 的 `PoolTransferResult` 新增 `restorable_prefix_pages` 元数据, 用于多 rank 场景下由调用方对可恢复前缀页集合求交; `components/__init__.py` 导出新枚举; 测试文件 `test_unified_radix_cache_unittest.py` 在 `test_prev_prefix_len` 中开启 `track_adopted_ranges` 并断言 `adopted_ranges[ComponentType.FULL]` 的区间正确性。

关键文件:

- `python/sglang/srt/mem_cache/unified_cache/components/swa_component.py` (模块 缓存组件; 类别 `source`; 类型 `core-logic`; 符号 `build_external_linker_transfer`, `update_external_linker_load`) : SWA 组件首次实现外部链接器钩子, 包含窗口页对齐、`TRAILING_PAGES` 策略、`full`→SWA 映射与 `req.kv` 回写, 是契约落地最复杂的组件。
- `python/sglang/srt/mem_cache/unified_cache/components/full_component.py` (模块 缓存组件; 类别 `source`; 类型 `core-logic`; 符号 `_full_allocator`, `build_external_linker_transfer`, `update_external_linker_load`) : Full 组件为整个外部链接器提供 KV 主数据的 `OFFLOAD/LOOKUP/LOAD` 实现, 并抽象出 `_full_allocator` 处理 SWA 开启时的池选择。
- `python/sglang/srt/mem_cache/unified_cache/components/tree_component.py` (模块 组件契约; 类别 `source`; 类型 `core-logic`; 符号 `LRURefreshPhase`, `LinkerTransferPhase`, `ExternalLinkerLoadPhase`, `build_external_linker_transfer`) : 定义外部链接器的阶段枚举与组件基类钩子, 是整个契约的骨架, 所有组件实现都依赖这里的抽象。
- `python/sglang/srt/mem_cache/unified_cache/unified_tree_core.py` (模块 树核心; 类别 `source`; 类型 `core-logic`) : 把 `external_cache_stored` 状态、`adopted_ranges` 记录和外部链接器开关接入树核心的插入 / 拆分裂 / 备份路径, 是状态机集成的关键文件。
- `python/sglang/srt/mem_cache/base_prefix_cache.py` (模块 前缀缓存; 类别 `source`; 类型 `core-logic`; 符号 `record_adopted_range`) : 为 `InsertResult` 增加 `adopted_ranges` 数据模型和 `record_adopted_range` 方法, 并新增 `InsertParams.track_adopted_ranges` 开关, 是所有组件记录采用范围的数据基础。
- `python/sglang/srt/mem_cache/unified_cache/components/mamba_component.py` (模块 缓存组件; 类别 `source`; 类型 `core-logic`; 符号 `build_external_linker_transfer`) : Mamba 组件通过显式 `AssertionError` 声明暂不支持外部链接器, 防止未来误用。
- `python/sglang/srt/mem_cache/hicache_storage.py` (模块 缓存存储; 类别 `source`; 类型 `core-logic`) : 为 `PoolTransferResult` 增加 `restorable_prefix_pages` 字段, 描述

TRAILING_PAGES 池在节点边界上的可恢复前缀页集合，供多 rank 调用方求交。

- python/sglang/srt/mem_cache/unified_cache/components/__init__.py（模块 组件导出；类别 source；类型 core-logic）：导出两个新阶段枚举，保证组件模块的对外 API 一致。
- test/registered/unit/mem_cache/test_unified_radix_cache_unittest.py（模块 缓存测试；类别 test；类型 test-coverage）：验证 track_adopted_ranges 开启后 adopted_ranges 中 Full 组件区间记录正确，是唯一覆盖新契约语义的测试。

关键符号：build_external_linker_transfer, update_external_linker_load,
record_adopted_range, _full_allocator, update_component_on_insert_overlap,
recover_after_unevict, commit_insert_component_data

关键源码片段

python/sglang/srt/mem_cache/unified_cache/components/full_component.py

Full 组件为整个外部链接器提供 KV 主数据的 OFFLOAD/LOOKUP/LOAD 实现，并抽象出 _full_allocator 处理 SWA 开启时的池选择。

```
def _full_allocator(self):
    """返回独占 full-attention 池的分配器。"""
    # SWA 启用时 full 池与 SWA 池分离，需要单独选择
    allocator = self.cache.token_to_kv_pool_allocator
    return allocator.full_attn_allocator if self.cache.is_swa_enabled else allocator
```

```
def build_external_linker_transfer(
    self,
    phase: LinkerTransferPhase,
    node: Optional[UnifiedTreeNode],
    keys: Optional[Sequence[str]],
) -> Optional[PoolTransfer]:
    # OFFLOAD: 把设备上的整段 KV 连同每页哈希交给外部存储
    if phase == LinkerTransferPhase.OFFLOAD:
        if node is None or not node.hash_value:
            return None
        value = node.component_data[self.component_type].value
        if value is None:
            return None
        return PoolTransfer(
            name=PoolName.KV,
            device_indices=value.to(torch.int64), # 设备页索引，供远端读取
            keys=list(node.hash_value), # 每页哈希，用于远端去重
        )
```

```
if not keys:
    return None
```

```
# LOOKUP: 只查询远端是否存在这些页
```

```

if phase == LinkerTransferPhase.LOOKUP:
    return PoolTransfer(name=PoolName.KV, keys=list(keys))

# LOAD: 先按页数预留设备 KV 槽位, 缺页走本地驱逐腾位
if phase == LinkerTransferPhase.LOAD:
    allocator = self._full_allocator()
    num_tokens = len(keys) * self.cache.page_size
    shortfall = max(0, num_tokens - allocator.available_size())
    if shortfall:
        self.cache.evict(EvictParams(num_tokens=shortfall))
    slots = allocator.alloc(num_tokens)
    if slots is None:
        return None
    return PoolTransfer(
        name=PoolName.KV,
        device_indices=slots.to(torch.int64), # 远端写入的落点
        keys=list(keys),
    )

def update_external_linker_load(
    self,
    phase: ExternalLinkerLoadPhase,
    req: Req,
    full_transfer: PoolTransfer,
    transfer: PoolTransfer,
    prefix_len: int,
    *,
    insert_result: Optional[InsertResult] = None,
    canonical_full: Optional[torch.Tensor] = None,
) -> Optional[PoolTransfer]:
    # ABORT: 远端加载失败时释放本地预留的槽位
    if phase == ExternalLinkerLoadPhase.ABORT:
        self._full_allocator().free(transfer.device_indices)
        return None
    return transfer

```

[python/sglang/srt/mem_cache/unified_cache/components/tree_component.py](#)

定义外部链接器的阶段枚举与组件基类钩子, 是整个契约的骨架, 所有组件实现都依赖这里的抽象。

```

class LinkerTransferPhase(str, Enum):
    LOOKUP = "lookup" # 仅查询远端是否已有对应 KV 页
    LOAD = "load" # 向远端请求数据并写入本地池
    OFFLOAD = "offload" # 将本地设备页导出到远端存储

```

```

class ExternalLinkerLoadPhase(str, Enum):

```

```
PREPARE = "prepare" # 远端数据到达前预留本地槽位 / 映射
COMMIT = "commit" # 数据落盘后提交映射与请求状态
ABORT = "abort" # 加载失败, 释放 PREPARE 预留的资源
```

```
class TreeComponent(ABC):
    # ---- External Cache Linker Hooks ----

    def build_external_linker_transfer(
        self,
        phase: LinkerTransferPhase,
        node: Optional[UnifiedTreeNode],
        keys: Optional[Sequence[str]],
    ) -> Optional[PoolTransfer]:
        """构建本组件与外部缓存之间的一次直接传输。

        ``node`` 在 OFFLOAD 时携带设备页数据, 其他阶段为 None;
        ``keys`` 是设备未缓存尾部的每页哈希 (page 0 为第一个未缓存页),
        在 LOOKUP / LOAD 时提供, OFFLOAD 时取 ``node.hash_value``。
        默认返回 None, 表示该组件不参与外部链接。
        """
        return None

    def update_external_linker_load(
        self,
        phase: ExternalLinkerLoadPhase,
        req: Req,
        full_transfer: PoolTransfer,
        transfer: PoolTransfer,
        prefix_len: int,
        *,
        insert_result: Optional[InsertResult] = None,
        canonical_full: Optional[torch.Tensor] = None,
    ) -> Optional[PoolTransfer]:
        """准备、提交或中止本组件的一次直接加载。"""
        return transfer
```

评论区精华

该 PR 没有行内 review 评论, 仅有一条 [huangtingwei9988](#) 的 APPROVED。Issue 评论主要是作者触发 CI 重跑 (/rerun-test 与 /rerun-group) 以及机器人回报测试通过, AMD ROCm 网格失败但未在评论中展开。从实现可以推断设计者有意将 `external_cache_stored` 与 HiCache 的 `backupid` 状态分离, 使外部链接器存储过的祖先节点在 `_build_backup_kv_action` 中跳过重复备份; Mamba 组件则用显式断言标明能力边界, 避免后续误用。

- 外部链接器契约的设计权衡 (question): 未记录正式讨论; 契约边界和 Mamba 不支持以代码形式固化为后续约束。

风险与影响

- 风险：核心风险集中在默认路径的回归与边界状态的一致性上：
 - unified_tree_core.py 的插入 walk 在所有组件方法签名中新增 result: InsertResult，任何遗漏更新该签名的第三方组件或子类都会导致 TypeError；但仓库内组件均已同步。
 - record_adopted_range 目前只在 SWA 与 unevict 路径上被调用，Full 的普通插入通过 _insert_commit_step 和 _insert_walk_step 显式记录，若后续组件漏记会导致远端加载去重不完整。
 - external_cache_stored 在 _split_node 中传播但在 _add_new_node 中初始化为 False，新节点若由已存储节点派生，可能存在需要手工恢复标志的遗漏点。
 - swa_component.update_external_linker_load 中 req.kv 的 swa_evicted_seqlen 计算依赖 prefix_len 与窗口页数，若外部 linker 返回的 keys 顺序或页面边界与本地窗口不对齐，会引入静默错误。
 - 新开关 enable_external_cache_linker 默认 False，所有新增逻辑在未启用时不生效，回归面被控制在契约接入后。
 - 影响：对现有用户与系统：无行为影响，因为外部链接器尚未接线且开关默认关闭。对开发团队：这是一次核心缓存模块的接口扩展，后续外部链接器 PR（如 #37151）将直接依赖这些钩子与元数据；同时 InsertResult/InsertParams 的字段扩展要求所有调用 cache.insert 的下游保持兼容。对测试体系：新增的 adopted_ranges 断言覆盖了插入去重语义，但尚缺少对 OFFLOAD/LOAD/ABORT 全生命周期的单元测试。
- 风险标记：新增契约默认关闭，组件方法签名变更，测试覆盖有限，跨模块状态依赖

关联脉络

- PR #35687 原始外部链接器完整实现（本 PR 的拆分来源）：本 PR 从 #35687 拆分而来，后续链接器接线与后端实现将继续沿用本 PR 定义的契约。
- PR #37151 [Unified Cache Linker][3/N]: Add backend-independent linker core: 同一外部链接器系列的后续 PR，在该契约之上增加后端无关的链接器核心，是直接依赖本契约的下一步实现。
- PR #35245 refactor(unified-memory): translate the KV write location once, at ForwardBatch construction: 同属 Unified Cache / 内存池演进方向，重构了 KV 写入位置的翻译流程，与本 PR 在 unified_tree_core 与 KvIndexTranslator 等路径上有潜在交互。