

PR #37151 完整报告

sgl-project/sglang

[Unified Cache Linker][3/N]: Add backend-independent linker core

合并时间: 2026-08-31 14:07

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/37151>

执行摘要

- 一句话: 新增后端无关外部缓存链路核心并接入缓存树
- 推荐动作: 值得精读。重点看三处设计: ① `_sync_restorable_prefix` 用 0/1 mask + MIN all-reduce 求跨 rank 稀疏集合交集, 避免“取局部最大值”落点不可恢复; ② `UnifiedCacheLinkerWrapper` 的「排队 + 异步完成」传输协议与锁 pin/unpin 机制, 兼顾按层加载与异常回滚; ③ `check_hicache_events` 的双轨事件轮询与卸载结果二次归约 (任一 rank 失败整体回滚)。建议后续 backend PR 合入前补充一次真实多卡端到端验证 (含 DMA 失败注入)。

功能与动机

PR body 明确说明这是从 #35687 拆出的第三块, 目标是 "Add the backend-independent external linker interface and tree-side wrapper", 并把 "direct load/offload lifecycle hooks" 集成进 `UnifiedRadixCache`。动机层面: 给 `UnifiedRadixCache` 提供直连外部 KV 存储 (L3) 的能力——不经过 host tier, 直接从设备池对接远端 KV 存储, 以支持更大规模的 KV 复用与跨节点缓存; 同时通过把巨型 PR 拆成多块 (#37091、#37098 与本 PR) 降低评审与回滚风险, 让契约与后端实现解耦。

实现拆解

1. 新增传输契约与树侧包装层 (`unified_cache_linker.py`, +571 行) - `UnifiedCacheLinker(ABC)` 定义 11 个抽象方法: `lookup`、`load`、`start_layer_wise_loading`、`cancel_queued_load`、`num_completed_loads`、`pop_completed_load`、`offload`、`num_completed_offloads`、`pop_completed_offload`、`reset`、`close`。- 契约采用「排队 + 异步完成」模型: `load` 只入队, 真正的传输由下一次 `start_layer_wise_loading` 触发并返回 layer-counter 消费者索引, 这是为配合按层推进的 CUDA graph 或流水线约束而设计。- `UnifiedCacheLinkerWrapper` 是树侧驱动, 持有 `hit_markers`、`pending_loads`、`pending_offloads` 三个状态容器; 构造时把 `tree_core.enable_external_cache_linker` 置 True、`write_through_threshold` 置 1, 完成「挂载即切模式」。
2. 生命周期接入 (`unified_radix_cache.py`, +52/-1) - 新增 `self.linker`: `Optional[UnifiedCacheLinkerWrapper] = None` 属性与 `init_cache_linker()` 入口。- `reset()` 与 `release_host_resources()` 分别补充 `linker.reset()`、`linker.close()` 调用, 保证后端先静默传输、再释放资源。

3. 热路径守卫钩子 - `match_prefix()` 在常规树匹配与 `finalizer` 之后追加 `linker.match()`，把外部可恢复长度合并进 `host_hit_length` 并暂存 `hit_markers`。- `init_load_back()` 开头用 `linker.has_hit(rid)` 分流，命中则走 `linker.load_back()` 直接回灌并插入树。- `_apply_cache_action()` 的 `BackupKV` 分支在挂载 `linker` 时改由 `linker.offload_nodes()` 异步持久化；`ReplaceWriteThroughOnNodeSplit` 分支同步把在途卸载重定向到拆分后的节点。- `release_aborted_request()` 增加 `linker.release_request(rid)` 清理排队加载并解锁。
4. 事件轮询分流 - `check_hicache_events()` 在挂载 `linker` 时走独立分支：先 `MIN all-reduce` 归约各 rank 的 `load/offload` 完成数，再 `drain_loads()` 与 `commit_completed_offloads()`；卸载成功位图二次 `all-reduce`，任一 rank 失败即整体回滚。该分支直接 `return`，绕开原有 `HiCache` 控制队列。- `ready_to_load_host_cache()` 把启动权交给 `linker.start_layer_wise_loading()`。
5. 测试配套 - 新增 `test_unified_cache_linker.py` (+447 行)： `_FakeLinker` 用内存态实现全部抽象方法，覆盖挂载开关、稀疏集合交集、异步加载 / 卸载的锁 `pin/unpin`、失败卸载回滚拆分碎片、`split action` 重定向、`reset` 静默顺序、`cancel` 排队加载等 9 个用例。- `test_hiradix_pp_sync_drain.py` 的 `_make_cache` 夹具补 `cache.linker = None`，适配新属性。

关键文件：

- `python/sglang/srt/mem_cache/unified_cache/unified_cache_linker.py`（模块 缓存链路；类别 `source`；类型 `core-logic`；符号 `UnifiedCacheLinker`, `UnifiedCacheLinkerWrapper`, `ExternalCacheHitMarker`, `lookup`）：本 PR 的核心新文件：定义后端无关的 `UnifiedCacheLinker` 传输契约（`lookup/load/offload` 等 11 个抽象方法）与树侧驱动 `UnifiedCacheLinkerWrapper`（`match` 探测、`load_back` 回灌、`offload` 原子持久化、锁 `pin` 管理）。所有后续外部 KV 存储后端都将基于此接口实现。
- `python/sglang/srt/mem_cache/unified_radix_cache.py`（模块 缓存核心；类别 `source`；类型 `core-logic`；符号 `init_cache_linker`, `match_prefix`, `init_load_back`, `check_hicache_events`）：外部缓存链路 with 既有统一缓存树的唯一接入点：新增 `linker` 属性、`init_cache_linker` 入口，并在 `match_prefix`、`init_load_back`、`_apply_cache_action`（`BackupKV` / `ReplaceWriteThroughOnNodeSplit`）、`release_aborted_request`、`check_hicache_events`、`ready_to_load_host_cache` 六处热路径挂载守卫钩子。改动虽小但影响面广，决定外部缓存何时接管写穿与事件轮询。
- `test/registered/unit/mem_cache/test_unified_cache_linker.py`（模块 链路测试；类别 `test`；类型 `test-coverage`；符号 `_FakeLinker`, `test_cache_linker_attachment_is_backended_independent`, `test_restorable_prefix_intersects_sparse_rank_results`, `test_async_offload_pins_node_until_completion`）：用 `_FakeLinker` 在内存中模拟后端，覆盖挂载开关、稀疏集合交集、异步加载 / 卸载锁 `pin/unpin`、失败卸载回滚拆分碎片、`split action` 重定向、`reset` 静默顺序、`cancel` 排队加载等关键状态机，是接口契约唯一的行为级文档。
- `test/registered/unit/mem_cache/test_hiradix_pp_sync_drain.py`（模块 PP 同步；类别 `test`；类型 `test-coverage`；符号 `_make_cache`）：夹具补 `cache.linker = None`，适配 `UnifiedRadixCache` 新属性，防止既有 PP 同步测试因新属性缺失而失败。

关键符号：UnifiedCacheLinker.lookup, UnifiedCacheLinker.load, UnifiedCacheLinker.start_layer_wise_loading, UnifiedCacheLinker.offload, UnifiedCacheLinkerWrapper.match, UnifiedCacheLinkerWrapper._sync_restorable_prefix, UnifiedCacheLinkerWrapper.load_back, UnifiedCacheLinkerWrapper.offload_nodes, UnifiedCacheLinkerWrapper.release_request, UnifiedRadixCache.init_cache_linker, UnifiedRadixCache.check_hicache_events

关键源码片段

python/sglang/srt/mem_cache/unified_radix_cache.py

外部缓存链路与既有统一缓存树的唯一接入点：新增 linker 属性、init_cache_linker 入口，并在 match_prefix、init_load_back、_apply_cache_action (BackupKV / ReplaceWriteThroughOnNodeSplit)、release_aborted_request、check_hicache_events、ready_to_load_host_cache 六处热路径挂载守卫钩子。改动虽小但影响面广，决定外部缓存何时接管写穿与事件轮询。

```
# unified_radix_cache.py -- 外部缓存链路的树侧接入点
# 原则：所有 linker 钩子都以 self.linker is not None 守卫，
# 默认（未挂载）路径与原先完全一致，避免影响现有 HiCache 行为。
```

```
def init_cache_linker(self, cache_linker: UnifiedCacheLinker) -> None:
```

```
    """把外部 KV 存储直连到设备池上。"""
```

```
    # 树侧只保存包装层，主树文件不感知具体后端；
```

```
    # 包装层构造时会自动打开树侧开关并压低写穿阈值。
```

```
    self.linker = UnifiedCacheLinkerWrapper(self, cache_linker)
```

```
def match_prefix(self, params: MatchPrefixParams) -> MatchResult:
```

```
    result = self.tree_core.match_prefix(params)
```

```
    self._apply_cache_actions(result.cache_actions)
```

```
    for component in self._components_tuple:
```

```
        result = component.finalize_match_result_in_cache(params, result)
```

```
    # 常规 match 结束后，再交给 linker 探测外部存储的可恢复尾部
```

```
    if self.linker is not None and params.req is not None:
```

```
        result = self.linker.match(params.key, params.req, result)
```

```
    return result
```

```
def _apply_cache_action(self, action: CacheAction | ComponentAction) -> None:
```

```
    # ... 其余 action 分支保持不变 ...
```

```
    elif isinstance(action, BackupKV):
```

```
        # 挂载 linker 后，写穿语义由外部存储异步接管；
```

```
        # 未挂载时退回原有 HiCache D→H backup 路径
```

```
        if self.linker is not None:
```

```
            self.linker.offload_nodes(action.node_ids)
```

```
        else:
```

```
            self._execute_and_commit_kv_backup(action)
```

```
def check_hicache_events(self) -> None:
```

```
    """每个 scheduler step 轮询异步事件；linker 路径在此分流。"""
```

```

if self.linker is not None:
    # 先用 MIN 归约各 rank 的完成数，保证所有 rank 消费一致的
    # 批次数量，避免部分 rank 提前消费造成跨 rank 不一致
    finish_counts = torch.tensor(
        [
            self.linker.num_completed_loads(),
            self.linker.num_completed_offloads(),
        ],
        dtype=torch.int,
        device="cpu",
    )
    self._all_reduce_attn_groups(finish_counts, torch.distributed.ReduceOp.MIN)
    load_count, offload_count = map(int, finish_counts.tolist())
    self.linker.drain_loads(load_count)
    local_successes = self.linker.take_completed_offloads(offload_count)
    if local_successes:
        # 卸载结果再归约一次：只要有一个 rank 失败就整体回滚
        successes = torch.tensor(local_successes, dtype=torch.int, device="cpu")
        self._all_reduce_attn_groups(successes, torch.distributed.ReduceOp.MIN)
        self.linker.commit_completed_offloads(
            [bool(success) for success in successes.tolist()]
        )
    return # linker 路径完成后直接返回，不再走 HiCache 控制队列
# ... 原有 HiCache 事件处理逻辑 ...

```

评论区精华

本 PR 没有 review 评论，reviewer [huangtingwei9988](#) 直接 APPROVED，说明接口与树侧接入方案在内部评审中无争议。实际讨论集中在 issue 评论区的 CI 复跑：

- 作者两次 /rerun-test: test_unified_cache_linker.py 与 test_hiradix_pp_sync_drain.py 在 ubuntu-latest 均通过。
- 作者一次 /rerun-group radix_cache/unified_radix_tree: 在 4-gpu-h100、4-gpu-b200、8-gpu-h200 上共 8 组多卡 unified radix cache 用例全部通过，验证了跨 rank MIN 归约在真实多卡环境下的正确性。
- 未决事项：PR body 中 AMD ROCm 7.2 CI 运行失败（Run #33325476754），评论中没有任何说明，无法确认是否与本次变更相关。
- CI 复跑验证单测与多卡回归 (testing): ubuntu-latest 单测与多卡 H100/B200/H200 回归全部通过，跨 rank MIN 归约逻辑在真实多卡环境验证正确。
- AMD ROCm 7.2 CI 失败未澄清 (other): 无法确认是否与本次变更相关，建议后续 PR 跟进澄清。
- Review 直接通过 (other): 已合入，无遗留 review 意见。

风险与影响

- 风险：

1. 热路径分支增加：match_prefix、init_load_back、check_hicache_events、_apply_cache_action、release_aborted_request 都新增了守卫分支。缺省 linker=None 时零开销，但 check_hicache_events 的 linker 分支直接 return，意味着挂载后原有 HiCache 事件轮询（ack_write_queue、ack_load_queue）整体停用，未来若出现「外部存储 + host tier」共存需求需显式校验互斥。
2. 锁生命周期依赖异常处理：pending_loads、pending_offloads 通过 inc_lock_ref、dec_lock_ref 机制 pin 住节点，任何异常路径漏调 dec_lock_ref 都会泄漏锁；测试覆盖了 cancel 与失败回滚，但真实后端 DMA 失败路径尚无验证。
3. 跨 rank 一致性假设：_sync_restorable_prefix 与 check_hicache_events 依赖 _all_reduce_attn_groups 的 MIN 归约并要求各 rank 同步调用，PP 长流水线或 CP 组合下的额外同步等待需后续性能评估。
4. 全局副作用：UnifiedCacheLinkerWrapper.__init__ 无条件把 write_through_threshold 改为 1，是对共享 cache 对象的全局改写。
5. CI 缺口：AMD ROCm 7.2 运行失败未澄清；本 PR 无真实后端接入，接口稳定性有待后续 backend PR 验证。- 影响：对用户：无直接可见功能变化——linker 缺省为 None，所有钩子短路，现有 HiCache 路径行为不变。对系统：UnifiedRadixCache 核心热路径新增 8 处守卫分支，后续所有 cache 相关修改都需同时考虑“挂载 / 未挂载”两种模式；check_hicache_events 形成双轨事件轮询。对团队：这是外部缓存链路系列的关键基座，为后续真实后端落地提供稳定接口，_FakeLinker + 多卡回归构成可靠安全网，可支撑后续并行开发。影响程度：中，属于基础设施分层改动，非线上行为变更。- 风险标记：热路径新增守卫分支，check_hicache_events 双轨互斥，锁生命周期依赖异常处理，跨 rank 一致性依赖 all-reduce，AMD ROCm CI 失败未澄清，缺真实后端端到端验证

关联脉络

- PR #35687 原始大 PR（本 PR 的拆分来源）：本 PR body 明确说明是 #35687 拆出的第 3 块，主题完全一致。后续 block 都将沿此主线合入。
- PR #37091 前序拆分（第 1 块）：PR body 标注为本 PR 的 previous split，同属 unified cache linker 系列。
- PR #37098 前序拆分（第 2 块）：PR body 标注为本 PR 的 previous split，同属 unified cache linker 系列。
- PR #36798 [HiCache] Align chunked CUDA host registrations: 同属 mem_cache / hicache 存储链路演进，共享 memory pool 与 host 注册基础设施，本 PR 的 linker 路径与其并存。
- PR #36958 [mem_cache] Keep req.kv non-optional and key KV ownership on req_pool_idx: 对 UnifiedRadixCache 与调度器所有权建模的重构，与本 PR 修改同一文件域，是 external linker 落地的依赖基础。