

PR #29173 完整报告

sgl-project/sglang

feat: Session-reference-aware Unified Radix Cache for agentic multi-turn workloads

合并时间: 2026-08-02 13:43

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29173>

执行摘要

- 一句话: 会话感知驱逐的 Unified Radix Cache, 提升 agentic 多轮命中率
- 推荐动作: 值得精读。重点学习: UnifiedLRUList 的 mid/cursor 分区哨兵设计 (O(1) 未引用优先驱逐)、软保护 (soft-protected) 与硬 pin 的语义区别、SWA 按窗口长度精确记账避免重复引用、跨组件原子驱逐保护 (`_can_evict_leaf_atomically`)、以及用 session generation + closed tombstone 解决 in-flight 竞态的手法。同时留意两个已承认的 follow-up: 会话引用 TTL、close 后分区切换导致的 recency 失真。

功能与动机

PR body 明确说明: 在多轮推理 (agentic workflow、RL rollouts) 场景中, 活跃会话跨轮次持续积累可复用 KV 前缀; 内存压力下标准 radix cache 只按配置的缓存策略驱逐, 不考虑前缀是否仍被活跃会话引用, 可能逐出活跃会话前缀却保留无关未引用 KV, 导致后续轮次重算、命中率和吞吐下降。因此需要让驱逐排序感知会话引用 (`is_referenced` 优先于 `base_eviction_priority`), 并让会话关闭只解除引用、保留 KV 供常规回收复用。

实现拆解

1. 配置与入口改造: `server_args.py` 保留 `--enable-session-radix-cache` 开关并移除“必须配合 `--radix-eviction-policy priority`”的旧约束; `mem_cache/registry.py` 新增校验, 仅 `UnifiedRadixCache` 允许开启 (否则启动告警); `scheduler.py` 中 `open_session / close_session` 转发到缓存的 `open_radix_session / release_radix_session`, 并增加 `init_session_radix_cache_guard` 兜底提示。
2. 会话引用追踪核心: 新增 `unified_cache/session_ref_tracker.py`, 以 `UnifiedSessionRefTracker` dataclass 组合进 `UnifiedRadixCache` (遵守仓库 `general-code-style` 的“不用 mixin”约定), 统一管理 closed-session tombstone (上限 8192, 防 close 后迟到请求重新挂引用)、会话代际 generation (open 时递增, 旧在途请求注册被拒) 与 `register_session_ref / release_radix_session` 入口。
3. 组件级引用记账: `TreeComponent` 抽象类增加 per-session 叶子索引 `_session_leaves`、`ComponentData.session_ref / session_ids`, 以及 `register_session_leaf`、`release_session`、`discard_deleted_session_leaf` (节点被驱逐时引用回退到最近可复用祖先) 与 `validate_session_state` 一致性校验。FULL 组件把整条路径计入 `session_ref` (`advance/recede` 时仅更新叶子到旧祖先之间的增量区间); SWA 组件用 `_session_leaf_covered_len` 记录每个叶子实际覆盖的滑窗长度, 避免多窗口重复计数;

Mamba 组件只对叶子状态计数。

4. 驱逐策略改造: unified_tree_core.py 的 UnifiedLRUList 引入“引用分区”构造 (is_referenced 谓词、mid 分区哨兵、cursor 游走哨兵), device 与 host 两层 LRU 都按“未引用在前、引用在后”布局; FULL 组件的驱逐堆键改为 (is_referenced, ref_count, base_priority), 关闭功能时保持原 get_priority 直接路径; _cascade_evict 增加跨组件保护, 防止无引用组件连带驱逐被引用的高优先级组件 (SWA 叶子原子驱逐会连带 FULL/Mamba)。
5. 生命周期集成与清理: UnifiedRadixCache.cache_finished_req 在成功插入后调用 register_session_ref(req) (排除 FINISH_ABORT 与流式会话), 并相应调整 disaggregation/prefill.py 中 finished_reason 的设置顺序; 删除旧 session_radix_cache.py (121 行) 与 test/manual/core/test_session_radix_cache.py, 新增 registered 单测 test_session_unified_radix_cache.py (所有权、注册释放、stale generation、unreferenced-first 驱逐) 与文档 docs_new/docs/advanced_features/session_radix_cache.mdx。

关键文件:

- python/sglang/srt/mem_cache/unified_cache/session_ref_tracker.py (模块 会话追踪; 类别 source; 类型 core-logic; 符号 UnifiedSessionRefTracker, post_init, reset, session_id_for_req): 本 PR 的核心新增模块: 以组合方式承载会话生命周期 (open/close, generation, tombstone), 是注册与释放引用的唯一入口, 也是与 SessionController 对接的纽带。
- python/sglang/srt/mem_cache/unified_cache/unified_tree_core.py (模块 树内核; 类别 source; 类型 core-logic; 符号 UnifiedLRUList, cursor_begin, cursor_next, cursor_end): LRU 列表引入 referenced/unreferenced 分区与 cursor 游走哨兵, device/host 驱逐两条路径都依赖它实现未引用优先; 同时新增 _session_lru_predicate 与 _cascade_evict 跨组件保护。
- python/sglang/srt/mem_cache/unified_cache/components/tree_component.py (模块 组件抽象; 类别 source; 类型 core-logic; 符号 reset_session_state, session_ref, _can_evict_leaf_atomically, _refresh_session_partition): 会话引用语义的抽象地基: per-session 叶子索引、覆盖记账抽象方法、注册 / 释放 / 回退逻辑与跨组件原子驱逐保护, FULL/SWA/Mamba 都基于它实现。
- python/sglang/srt/mem_cache/unified_cache/components/swa_component.py (模块 滑动窗口组件; 类别 source; 类型 core-logic; 符号 reset_session_state, _walk_session_coverage, _inc_session_coverage, _dec_session_coverage): SWA 的会话引用必须按滑动窗口长度精确记账 (_session_leaf_covered_len), 避免整条前缀路径重复计数; 同时 device/host 驱逐走 cursor 双 pass。
- python/sglang/srt/mem_cache/unified_cache/components/mamba_component.py (模块 曼巴组件; 类别 source; 类型 core-logic; 符号 _inc_session_coverage, _dec_session_coverage, _advance_session_coverage, _recede_session_coverage): Mamba 只对叶子状态计会话引用 (路径祖先不计数), 并保持叶子拆分时 session_ref/session_ids 复位与驱逐 cursor 切换。

- python/sglang/srt/mem_cache/unified_radix_cache.py (模块 统一缓存; 类别 source; 类型 core-logic; 符号 cache_finished_req, open_radix_session, ensure_session_generation, release_radix_session) : 统一缓存入口: 组装 UnifiedSessionRefTracker、在 cache_finished_req 成功插入后注册引用, 并暴露 open/ensure/release 三个公开方法给调度器。
- python/sglang/srt/mem_cache/session_radix_cache.py (模块 旧版缓存; 类别 source; 类型 deletion; 符号 SessionRadixCacheMixin, _reset_session_radix_state, _ensure_session_radix_state, _remember_closed_session) : 旧 SessionRadixCacheMixin 整体删除 (121 行), 会话功能从普通 RadixCache/HiRadixCache 移出, 收敛到 UnifiedRadixCache 组合实现, 避免双实现漂移。
- test/registered/unit/mem_cache/test_session_unified_radix_cache.py (模块 会话缓存; 类别 test; 类型 test-coverage; 符号 TestSessionCacheOwnership, TestRadixCacheSessionRemoval, TestSessionUnifiedRadixCache, test_register_and_release_update_full_component_reference) : 会话引用的核心单测: 验证只有 UnifiedRadixCache 拥有会话追踪、注册 / 释放更新 session_ref、stale generation 拒绝、以及 unreferenced-first 驱逐顺序。

关键符号: UnifiedSessionRefTracker.register_session_ref,
 UnifiedSessionRefTracker.release_radix_session,
 UnifiedSessionRefTracker.open_radix_session,
 UnifiedSessionRefTracker.ensure_session_generation,
 TreeComponent.register_session_leaf, TreeComponent.release_session,
 TreeComponent.discard_deleted_session_leaf,
 TreeComponent._can_evict_leaf_atomically, TreeComponent._refresh_session_partition,
 SWAComponent._walk_session_coverage, SWAComponent._inc_session_coverage,
 SWAComponent._dec_session_coverage, SWAComponent._advance_session_coverage,
 SWAComponent._recede_session_coverage, MambaComponent._inc_session_coverage,
 MambaComponent._dec_session_coverage, FullComponent._session_ref_eviction_strategy,
 UnifiedLRUList.cursor_begin, UnifiedLRUList.cursor_next,
 UnifiedLRUList.cursor_end, UnifiedTreeCore._session_lru_predicate,
 UnifiedRadixCache.cache_finished_req

关键源码片段

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

本 PR 的核心新增模块: 以组合方式承载会话生命周期 (open/close、generation、tombstone), 是注册与释放引用的唯一入口, 也是与 SessionController 对接的纽带。

"""会话引用追踪器: 按 session_id 给 KV 打标签, close 时只解除引用、不立即释放 KV。

被 UnifiedRadixCache 组合 (composition) 而不是 mixin 继承, 符合仓库 general-code-style 规则。
 """

```
@dataclass(kw_only=True)
class UnifiedSessionRefTracker:
```

"""每个组件各自维护 session_ids 与 session_ref, tracker 只负责跨组件的生命周期协调。"""

components: tuple[TreeComponent, ...]

tree_core: UnifiedTreeCore

enable_session_radix_cache: bool

def __post_init__(self) -> None:

self.reset()

def reset(self) -> None:

有界 tombstone: 防止“请求在 close 之后才完成”把引用重新挂回去;

8192 次 close 后最早条目被淘汰, 属可接受的极端迟到竞态。

self._closed_session_ids: OrderedDict[str, None] = OrderedDict()

会话代际: 每次 open 递增, 旧的在途请求因 generation 不匹配被拒绝注册。

self._session_incarnation_counter: int = 0

self._session_generations: dict[str, int] = {}

for component in self.components:

component.reset_session_state()

def session_id_for_req(self, req: Req) -> Optional[str]:

顶层 session_id 与流式 session 对象两种来源, 统一摘出稳定 id。

session_id = req.session_id

if session_id is None and req.session is not None:

session_id = req.session.session_id

return session_id

def register_session_ref(self, req: Req) -> None:

"""请求成功落缓存后调用: 把可复用叶子登记到各组件。"""

if not self.enable_session_radix_cache:

return

session = req.session

if session is not None and session.streaming:

return # 流式会话的 KV 由 StreamingSession 自己管理

session_id = self.session_id_for_req(req)

if session_id is None or session_id in self._closed_session_ids:

return # close 之后的迟到请求直接丢弃

current_generation = self._session_generations.get(session_id)

if current_generation is None or req.session_generation != current_generation:

logger.warning("register_session_ref called for stale request; Skip it.")

return # 旧代际请求, 禁止污染新会话

assert req.last_node is not None

last_node = self.tree_core.node_by_id(req.last_node)

if last_node is self.tree_core.root_node:

return

for component in self.components:

```

# 各组件解析自己语义下的可复用叶子:
# FULL 是整条前缀路径, SWA 是窗口尾部, Mamba 是叶子状态。
leaf = component.resolve_session_leaf(req, last_node)
component.register_session_leaf(session_id, leaf)

def release_radix_session(self, session_id: str) -> int:
    """关闭会话: 解除所有引用, KV 本身留给常规驱逐回收 (软保护而非 pin) 。”"""
    if not self.enable_session_radix_cache or session_id is None:
        return 0
    if session_id in self._closed_session_ids:
        return 0 # 幂等: 重复 close 是 no-op

    self._remember_closed_session(session_id)
    self._session_generations.pop(session_id, None) # 代际作废

    indexed = 0
    for component in self.components:
        indexed += component.release_session(session_id)
    logger.info(
        "release_session %s: indexed %d component leaves", session_id, indexed
    )
    return 0

def open_radix_session(self, session_id: str) -> Optional[int]:
    """打开会话: 清掉 tombstone 并分配新代际, 旧在途请求随即失效。"""
    self._closed_session_ids.pop(session_id, None)
    self._session_incarnation_counter += 1
    self._session_generations[session_id] = self._session_incarnation_counter
    return self._session_incarnation_counter

def ensure_session_generation(self, session_id: str) -> int:
    """未见过的 session 先隐式 open 一次, 保证每个请求都有可校验代际。"""
    generation = self._session_generations.get(session_id)
    if generation is None:
        generation = self.open_radix_session(session_id)
    return generation

```

python/sglang/srt/mem_cache/unified_cache/unified_tree_core.py

LRU 列表引入 referenced/unreferenced 分区与 cursor 游走哨兵, device/host 驱逐两条路径都依赖它实现未引用优先; 同时新增 _session_lru_predicate 与 _cascade_evict 跨组件保护。

```

class UnifiedLRUList:
    """带会话引用分区的 LRU 列表。

```

分区布局: [head .. mid) 是 session 引用中的节点, (mid .. tail] 是未引用节点, 驱逐从 tail 向 head 走, 先消耗未引用 KV; mid 与 cursor 是带 lock_ref 的哨兵, 不会被当作真实候选节点。

```

"""

```

```

def __init__(
    self,
    component_type: ComponentType,
    tree_components: tuple[ComponentType, ...],
    use_host_ptr: bool = False,
    is_referenced: Optional[Callable[[UnifiedTreeNode], bool]] = None,
):
    self.component_type = component_type
    # 指针槽: host LRU 用偏移量避免与 device 指针在同一节点上冲突。
    self._pt: int = component_type + (_NUM_COMPONENT_TYPES if use_host_ptr else 0)
    self.head = UnifiedTreeNode(tree_components)
    self.tail = UnifiedTreeNode(tree_components)
    self.head.lru_next[self._pt] = self.tail
    self.tail.lru_prev[self._pt] = self.head
    self.cache: dict[int, UnifiedTreeNode] = {}
    self._is_referenced = is_referenced
    self.mid: Optional[UnifiedTreeNode] = None
    self.cursor: Optional[UnifiedTreeNode] = None
    if is_referenced is not None:
        # 分区与游走哨兵都加锁, 驱逐遍历时不会把它们当候选节点。
        self.mid = UnifiedTreeNode(tree_components)
        self.cursor = UnifiedTreeNode(tree_components)
        for ct in tree_components:
            for node in (self.mid, self.cursor):
                node.component_data[ct].lock_ref = 1
                node.component_data[ct].host_lock_ref = 1
        self._add_node_after(self.head, self.mid)

def _add_node(self, node: UnifiedTreeNode):
    # 按 is_referenced 决定插入哪个分区: 引用节点进 [head .. mid], 其余进 (mid .. tail)。
    if self._is_referenced is None or self._is_referenced(node):
        self._add_node_after(self.head, node)
    else:
        self._add_node_after(self.mid, node)

def cursor_begin(self):
    # 把游走哨兵挂到 LRU 最尾, 驱逐按 tail -> head 方向推进。
    if self.cursor.lru_prev[self._pt] is not None:
        self._remove_node(self.cursor)
    self._add_node_after(self.tail.lru_prev[self._pt], self.cursor)

def cursor_next(self, *, host_lock: bool = False):
    """返回下一个可驱逐节点 (跳过带锁节点); 越过 head 表示本轮走完。"""
    pt = self._pt
    ct = self.component_type
    x = self.cursor.lru_prev[pt]
    while x is not self.head:
        cd = x.component_data[ct]
        if (cd.host_lock_ref if host_lock else cd.lock_ref) == 0:

```

```

        break
    x = x.lru_prev[pt]
    if x is self.head:
        return None
    self._remove_node(self.cursor)
    self._add_node_after(x.lru_prev[pt], self.cursor)
    return x

def cursor_end(self):
    """遍历结束摘掉哨兵，避免污染真实 LRU。"""
    self._remove_node(self.cursor)

```

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

会话引用语义的抽象地基：per-session 叶子索引、覆盖记账抽象方法、注册 / 释放 / 回退逻辑与跨组件原子驱逐保护，FULL/SWA/Mamba 都基于它实现。

```

class TreeComponent(ABC):
    # ... 既有抽象方法省略，以下为本次新增的会话引用核心逻辑 ...

    def _can_evict_leaf_atomically(self, node: UnifiedTreeNode) -> bool:
        """跨组件联动的原子驱逐保护。

        SWA 叶子被整体驱逐时会连带回收 FULL 与 Mamba；
        若本组件无引用却要连带驱逐一个引用中的高优先级组件，就拒绝。
        """
        if self.session_ref(node) > 0:
            return True # 自己被引用，驱逐后引用信息随节点删除，安全
        priority = self.eviction_priority(is_leaf=False)
        return not any(
            comp.eviction_priority(is_leaf=False) >= priority
            and comp.session_ref(node) > 0
            for comp in self.tree_core.components
        )

    def register_session_leaf(
        self, session_id: str, leaf: Optional[UnifiedTreeNode]
    ) -> None:
        """把新叶子挂到会话下；若已有祖先叶子，只增补增量区间 (advance) 。"""
        if (
            not self.tree_core.enable_session_radix_cache
            or leaf is None
            or leaf is self.tree_core.root_node
        ):
            return
        current_leaves = self._session_leaves[session_id]
        if leaf in current_leaves:
            return
        old_ancestor = self._nearest_session_ancestor(leaf, current_leaves)

```

```

self._advance_session_coverage(session_id, leaf, old_ancestor)
self._mark_session_leaf(session_id, leaf)
if old_ancestor is not None:
    self._unmark_session_leaf(session_id, old_ancestor)

def release_session(self, session_id: str) -> int:
    """会话关闭：对每个叶子 dec 一次，再摘除叶子标记；KV 保持可复用。"""
    leaves = tuple(self._session_leaves.get(session_id, ()))
    for leaf in leaves:
        self._dec_session_coverage(session_id, leaf)
        self._unmark_session_leaf(session_id, leaf)
    return len(leaves)

def discard_deleted_session_leaf(self, node: UnifiedTreeNode) -> None:
    """节点被驱逐时回调：引用回退到最近的可复用祖先，保证计数不泄漏。"""
    cd = node.component_data[self.component_type]
    for session_id in tuple(cd.session_ids or ()):
        leaves = self._session_leaves.get(session_id)
        assert leaves is not None and node in leaves
        fallback = self._find_reusable_session_leaf(node.parent)
        if fallback is not None and fallback in self._session_leaves.get(
            session_id, ()):
        ):
            fallback = None # 祖先已是会话叶子，无需再挂
        self._recede_session_coverage(session_id, node, fallback)
        self._unmark_session_leaf(session_id, node)
        if fallback is not None:
            self._mark_session_leaf(session_id, fallback)

```

评论区精华

ishandhanani (Issue 评论) : "IIUC the distinction seems to be:

1. RefAwareCache keeps active session KV resident under pressure. 2. SessionRadixCache tracks ownership and reclaims KV on session close. I wonder if we can share the existing session_id lifecycle instead of introducing a parallel rid lifecycle?" —— 最终方案采纳此建议，复用 req.session_id 与 SessionController 生命周期，废弃独立 rid 双优先级模型。

krishs0404 (Issue 评论) : "mixed-priority refs can leak within the same session_id... the suffix can still have high_ref == 1. release_ref decrements all nodes using the session's original RefInfo.is_high." —— 作者回应低优先级会话不应发高优生成请求，应记录并管理优先级不匹配；该双优先级模型在后续重写中被整体替换为按 session_id 单一引用 + generation 方案。

ishandhanani (重写后 full rereview) : 指出无显式 /open_session workflow 时旧实现会跳过 generation 校验 (session_generation=None)，close+reopen 后旧请求仍能注册；并指出 session 注册应放在成功 cache 插入生命周期而非仅 result processor (否则 disagg prefill / dLLM 完成路径丢失引用)。head 版本已把 register_session_ref 内置进

cache_finished_req, 并让 ensure_session_generation 为顶层请求预分配代际。

ispobock: "Do not use mixin. Ref: .claude/rules/general-code-style.md"; 同时指出未 close 的会话引用会永久保留、discard_deleted_session_leaf 只向上回退导致 refs 堆积在浅层热节点 ("unreferenced first degrades back toward plain LRU"), 建议 TTL 留作 follow-up; close 时 reset_node_mru 会把刚关闭的冷会话 KV 移到 MRU 端, 改变 recency。作者认同后者但认为保持 O(1) 较难, 同意留作后续 PR。

hzh0425: 要求补充 SWE Bench 对比测试 (DSV4 / Qwen3.5 的 Session+HiCache vs Plain HiCache), 作者在 8xH200 上给出数据; 并要求 FULL 驱逐堆用 flag 分支、不要改动原逻辑 (head 已实现), 同时提醒 SWA 叶子原子驱逐会连带 FULL/Mamba, 需考虑跨组件 session_ref (由 _can_evict_leaf_atomically 实现)。

- 与仓库并行 session-radix-cache 工作统一 session_id 生命周期 (design): 最终方案采纳: 会话参考完全绑定 req.session_id / SessionController 生命周期, 废弃独立 rid 与双优先级模型, 引入 session generation 提供确定性 close 语义。
- 混合优先级引用在同一 session 内泄漏 (correctness): 该双优先级模型在后续重写中被整体替换为按 session_id 单一引用 + generation 方案, 泄漏问题随之消解。
- 无显式 open_session 时 incarnation 校验被绕过 (P1) (correctness): head 版本通过 ensure_session_generation 为未见过的 session 预分配代际, register_session_ref 统一比较 req.session_generation, 测试 test_reopen_rejects_stale_generation 覆盖。
- 会话注册应放入成功 cache 插入生命周期 (P1) (correctness): head 将 register_session_ref 内置到 UnifiedRadixCache.cache_finished_req, 按 finished_reason 排除 FINISH_ABORT 后注册; disaggregation/prefill.py 相应调整 finished_reason 设置顺序。
- 拒绝 mixin, 改为组合 (general-code-style) (design): 重写为 UnifiedSessionRefTracker dataclass 组合进 UnifiedRadixCache, 删除 SessionUnifiedRadixCacheMixin; 测试静态断言 mixin 已移除。
- 从未 close 的会话引用永久滞留, 退化为普通 LRU (建议 TTL) (performance): 本 PR 接受现状, TTL 留作 follow-up PR。
- close 时分区切换改变 recency (reset_node_mru 移到 MRU 端) (performance): 本 PR 接受宏观 unreferenced-first 顺序, recency 保真作为已知权衡, 作者建议后续讨论实现。
- SWA/Mamba 全 referenced 时驱逐 O(n) 全表扫描 (performance): head 采用 mid/cursor 分区哨兵维护 referenced/unreferenced 两个分区, 未引用队列头部 O(1) 可达, 缓解该问题; 全部被引用时仍存在一次引用区遍历。
- SWA 关联驱逐需考虑 full/mamba 的 session_ref (design): 实现为 TreeComponent._can_evict_leaf_atomically: 本组件被引用可驱逐; 否则若存在更高或同级优先级且被引用的组件则拒绝原子驱逐。
- SWE Bench 额外验证 (DSV4 / Qwen3.5) (testing): DeepSeek-V4-Pro batch 128 device 命中率 0.418→0.510, Qwen3.5-397B batch 32 0.050→0.336; 数据发布于 PR 评论并附复现脚本。

风险与影响

- 风险:

1. 行为兼容性: `--enable-session-radix-cache` 现在只对 `UnifiedRadixCache` 生效; 旧启动命令若未启用 `SGLANG_ENABLE_UNIFIED_RADIX_TREE=1`, 启动仅告警 (`scheduler.py` 的 `init_session_radix_cache_guard`), 会话标签功能会静默失效, 升级用户需留意。
2. 跨组件原子驱逐: `SWA` 叶子被整体驱逐时连带回收 `FULL` 与 `Mamba`, `_can_evict_leaf_atomically` 依赖各组件 `eviction_priority` 大小比较; 未来调整组件优先级定义时可能误放行“引用中”的组件 `KV`。
3. 引用永久滞留: `session_ref_tracker.py` 中从未显式 `close` 的会话引用不会过期 (`ispobock` 指出), 配合 `discard_deleted_session_leaf` 只向祖先回退, 长期运行后引用会集中在浅层热节点, 驱逐排序退化为普通 `LRU`。
4. 性能开销: 开启后 `FULL` 堆键为三元组, 早期实测 100k 叶子堆建约 33 ms、峰值内存约 12 MiB (关闭状态下 `head` 已恢复直接 `get_priority` 路径); `SWA/Mamba` 双 pass 驱逐在全部被引用场景下仍需遍历引用分区 (`cursor` 遍历 $O(n)$, 但未引用分区头部可 $O(1)$ 到达)。
5. 竞态边界: `generation/tombstone` 已覆盖 `close` 后迟到请求与 `close/reopen` 场景, 但顶层请求依赖 `ensure_session_generation` 预分配代际, 若未来调整 `Scheduler` 调用顺序 (如 `open` 校验与 `tombstone` 清理顺序), 仍可能引入新竞态。
6. 内存占用: 每个树节点 `ComponentData` 增加 `session_ref` 与可选 `session_ids` set; 共享前缀大的会话会把 `session_id` 集合复制到多个节点, 虽比旧方案轻, 但在多会话共享长前缀时仍有累积开销。- 影响: 用户侧: `agentic` 多轮、`RL rollout`、`SWE-agent`、`tool-calling` 等负载显著受益——`DeepSeek-V4-Pro` 在 batch 128 下 `device` 命中率从 0.418 提升到 0.510, `Qwen3.5-397B-A17B` 在 batch 32 下从 0.050 提升到 0.336; 普通单轮负载默认关闭无影响。系统侧: 每节点增加少量引用计数内存, 调度器在会话 `open/close` 时多一次缓存回调, `FULL` 驱逐堆键在开启时变大。团队侧: 确立了 `UnifiedRadixCache` 上“组合而非 `mixin`”的扩展范式, 并验证了会话生命周期与缓存引用一致性的通用模式, 为后续 `TTL`、准入控制 (PR body 提到的 `ThunderAgent / Concur` 方向) 铺路。- 风险标记: 核心缓存路径变更, 跨组件驱逐联动, 会话引用永久滞留, `close` 后 `recency` 失真, 非 `Unified` 后端静默降级, 默认关闭的增量特性

关联脉络

- PR #33171 test: recover the config-namespace-migration deferrals: 与本 PR 同改 `test/registered/unit/mem_cache/test_unified_radix_cache_unittest.py`, 共同服务于 `UnifiedRadixCache` 的稳定性建设。
- PR #33170 config: route parallel config-leaf reads through `get_parallel()`: 同一批 `mem_cache/UnifiedRadixCache` 路径的配置读取重构; 本 PR 的 `enable_session_radix_cache` 接入与 `tree_core` 初始化顺序依赖这些配置读取语义。
- PR #33168 Fix the chunked-prefix-cache gate writing config the backends never read: 同为 `mem_cache` 配置门控语义修正: 后端实际读取的配置与写入位置不一致会导致功能静默失效, 与本 PR 中 `enable_session_radix_cache` 在非 `Unified` 后端静默降级的风险同源。

- PR #33126 perf(startup): skip unused PyTorch headers for KV VMM allocator stub: 同属 mem_cache/KV 内存子系统优化脉络，反映 UnifiedRadixCache 内核持续演进的上下文。