

# PR #30762 完整报告

sgl-project/sglang

fix(hicache/umbp): support DeepSeek-V4 hybrid HostPoolGroup (multi-po...

合并时间: 2026-08-13 15:40

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30762>

## 执行摘要

- 一句话: UMBP 支持 DSV4 混合 HostPoolGroup v2 多池接口
- 推荐动作: 值得精读: 这是 UMBP 从单池走向多池 v2 接口的关键实现, register\_mem\_host\_pool\_v2 / batch\_exists\_v2 的收窄查询与 fail-closed 语义设计值得借鉴; 审查 E2E 测试的断言方式 (storage cached\_tokens >= PAGE\_SIZE 且 storage\_backend == UMBPStore)。关注点: nightly-only 验证缺口、零拷贝静默回退、logical anchor v1 no-op 语义。

## 功能与动机

UMBStore 原先假设 mem\_pool\_host 是单一 KV 持有池, 而 DeepSeek-V4 HiCache 栈中 mem\_pool\_host 是 HostPoolGroup, 其 KV anchor 是只持有页索引、无物理 KV tensor 的 LogicalHostPool (get\_page\_buffer\_meta() 按设计返回 None)。这导致两个问题: 构造期解包 None 直接崩溃杀死 prefill worker; UMBStore 未实现 v2 多池 API, side pool 无法存储 / 加载。PR body 明确说明这是本 PR 的目标场景: 1 Prefill 节点 + 1 Decode 节点的 PD 分离下, UMBP 作为 L3 后端驱动 SWA / compressed KV / indexer / state 各 side pool。

## 实现拆解

按 4 步拆解:

1) 构造期探测加固: ump\_store.py \_\_init\_\_ 中将 get\_page\_buffer\_meta() 返回值先存为 meta 再解包, 逻辑 anchor 返回 None 时保留 dram\_page\_size=0, 交给 mori master 默认值 + PoolClient partial-tail 兜底; 2) 逻辑 anchor 识别与注册重构: register\_mem\_pool\_host 中一次性计算 \_kv\_anchor\_is\_logical (kv\_buffer is None), 跳过逻辑 anchor 的 RDMA 注册与 v1 I/O (batch\_get\_v1 / batch\_set\_v1 对逻辑 anchor 直接返回 [True], 对齐 MooncakeStore), 并把 RDMA 注册逻辑抽取为 \_register\_host\_buffer\_for\_zero\_copy() helper 供单池 / 多池复用; 3) v2 多池接口实现: register\_mem\_host\_pool\_v2 跳过 PoolName.KV、注册各 side pool 并做零拷贝注册; \_get\_hybrid\_page\_component\_keys 按 page\_first 单对象每页布局生成带池名后缀的存储 key; batch\_exists\_v2 实现 ALL\_PAGES / TRAILING\_PAGES 命中策略并按 final\_pages 逐步收窄查询; \_batch\_io\_v2 统一驱动 batch\_get\_v2 / batch\_set\_v2 的逐池 zero-copy get/put 与 put 去重; 4) 配套改动: memory\_pool\_host.py 为 LogicalHostPool 增加无操作 destroy() 满足 HostPoolGroup 销毁契约; 新增 test/registered/hicache/test\_hicache\_storage\_umbp\_backend.py 的 AMD 8-GPU E2E (round trip 验证 storage 层命中);

test/registered/unit/mem\_cache/test\_umbp\_store.py 增加防御性单元测试（逻辑 anchor 构造、短结果 fail-closed、跨池查询收窄）；test/run\_suite.py 注册 nightly-amd-8-gpu-mi35x-deepseek-v4-flash nightly 套件。

关键文件：

- python/sglang/srt/mem\_cache/storage/umbp/umbp\_store.py（模块 存储后端；类别 source；类型 core-logic；符号 \_register\_host\_buffer\_for\_zero\_copy, register\_mem\_host\_pool\_v2, \_get\_hybrid\_page\_component\_keys, batch\_exists\_v2）：核心实现文件，修复逻辑 anchor 探测崩溃并实现 v2 多池接口，是 PR 的主变更。
- test/registered/hicache/test\_hicache\_storage\_umbp\_backend.py（模块 端到端测试；类别 test；类型 test-coverage；符号 TestHiCacheStorageUMBPBackend, setUpClass, tearDownClass, \_launch\_server）：新增 AMD 8-GPU E2E 测试，验证 DSV4 混合 HostPoolGroup 经 UMBP 的 round trip，是唯一覆盖 v2 路径的端到端测试。
- test/registered/unit/mem\_cache/test\_umbp\_store.py（模块 单元测试；类别 test；类型 test-coverage；符号 MockLogicalHostPool, MockHybridSidePool, get\_page\_buffer\_meta, import\_umbp\_store\_module）：单元测试覆盖逻辑 anchor 构造、v2 查询收窄、fail-closed 语义，是 PR CI 中唯一能跑的 UMBP 测试。
- python/sglang/srt/mem\_cache/memory\_pool\_host.py（模块 内存池；类别 source；类型 core-logic；符号 destroy）：为 LogicalHostPool 补充无操作 destroy()，满足 HostPoolGroup 销毁契约，避免调度器关闭时隐藏子进程异常。
- test/registered/unit/mem\_cache/test\_hicache\_staged\_write\_back\_dispatch.py（模块 回写测试；类别 test；类型 test-coverage；符号 test\_host\_pool\_group\_destroys\_logical\_anchor）：补充 HostPoolGroup 销毁逻辑 anchor 的单元测试，守护 destroy() 契约。
- test/run\_suite.py（模块 测试套件；类别 test；类型 test-coverage）：注册 nightly-amd-8-gpu-mi35x-deepseek-v4-flash 套件，使新 E2E 测试可被 nightly 调度。

关键符号：register\_mem\_pool\_host, \_register\_host\_buffer\_for\_zero\_copy, register\_mem\_host\_pool\_v2, \_get\_hybrid\_page\_component\_keys, batch\_exists\_v2, \_batch\_io\_v2, batch\_get\_v2, batch\_set\_v2, destroy

## 关键源码片段

### python/sglang/srt/mem\_cache/storage/umbp/umbp\_store.py

核心实现文件，修复逻辑 anchor 探测崩溃并实现 v2 多池接口，是 PR 的主变更。

```
# python/sglang/srt/mem_cache/storage/umbp/umbp_store.py
# 逻辑 anchor 识别：DeepSeek-V4 混合 HostPoolGroup 的 KV anchor 是 LogicalHostPool,
# 只持有页索引、无物理 KV tensor。这里一次性计算标志位，供 v1 no-op 与 v2 注册复用，
# 避免在多个调用点重复 getattr 防御式判断。
def register_mem_pool_host(self, mem_pool_host: HostKVCache):
    super().register_mem_pool_host(mem_pool_host)
    # 仅支持 page_first 系列布局，这是 UMBP 零拷贝 / key 映射的前提
    assert self.mem_pool_host.layout in [
        "page_first", "page_first_direct", "page_head",
    ], "UMBP store only supports page_first, page_first_direct, or page_head layout"
```

```

# 逻辑 anchor 没有 kv_buffer, 无需也不能做 RDMA 注册;
# 真实的 side pool 缓冲由 register_mem_host_pool_v2() 逐个注册
self._kv_anchor_is_logical = self.mem_pool_host.kv_buffer is None
self._zero_copy_registered = False
if self._kv_anchor_is_logical:
    return

# 单池路径: 整块 KV 缓冲预注册到 RDMA IOEngine, 使 PoolClient 走 zero-copy
if self._register_host_buffer_for_zero_copy(mem_pool_host):
    self._zero_copy_registered = True

```

```

def _register_host_buffer_for_zero_copy(self, host_pool: HostKVCache) -> bool:
    """注册 host pool 的 KV 缓冲到 RDMA IOEngine, 供零拷贝传输使用。

```

单池路径 (register\_mem\_pool\_host) 与多池路径 (register\_mem\_host\_pool\_v2) 共用;  
返回 True 表示注册成功, False 表示跳过 / 失败 (调用方透明回退 staging buffer) 。

注意: 当前只处理 page\_first 布局下连续 kv\_buffer 的情形; 若后续支持 layer\_first 布局, 或 side pool 通过 get\_hybrid\_pool\_buffer() 暴露多缓冲 (例如 DSAIndexerPoolHost 的 index\_k\_with\_scale\_buffer), 必须扩展本分支逐个注册, 否则这些池会静默跳过零拷贝、走较慢的 staging buffer 路径。

```

"""
if self.client is None:
    return False
try:
    is_distributed = bool(self.client.is_distributed())
except Exception:
    is_distributed = False
if not is_distributed:
    return False
if not hasattr(self.client, "register_memory"):
    return False
if getattr(self, "_disable_zero_copy_register", False):
    return False

kv_buffer = getattr(host_pool, "kv_buffer", None)
if kv_buffer is None:
    return False
try:
    host_ptr = int(kv_buffer.data_ptr())
    host_size = int(kv_buffer.numel() * kv_buffer.element_size())
    # 大页场景下 mmap 区域会向上取整到巨页边界, RDMA ibv_reg_mr
    # 要求注册完整巨页, 因此优先使用 mapped_size
    allocator = getattr(host_pool, "allocator", None)
    mapped_size_fn = getattr(allocator, "mapped_size_for", None)
    mapped_size = mapped_size_fn(host_ptr) if mapped_size_fn is not None else
    getattr(allocator, "mapped_size", 0)
    if mapped_size > host_size:

```

```

        host_size = mapped_size
        ok = bool(self.client.register_memory(host_ptr, host_size))
    except Exception as exc:
        logger.warning("UMBPStore: register_memory failed (%s); falling back to staging buffer path.", exc)
        return False
    if ok:
        logger.info("UMBPStore: registered host KV buffer for RDMA zero-copy (ptr=0x%x, size=%d MB)", host_ptr, host_size // (1024 * 1024))
        return True
    logger.warning("UMBPStore: register_memory returned false; staying on staging buffer fallback path.")
    return False

```

## test/registered/hicache/test\_hicache\_storage\_umbp\_backend.py

新增 AMD 8-GPU E2E 测试，验证 DSV4 混合 HostPoolGroup 经 UMBP 的 round trip，是唯一覆盖 v2 路径的端到端测试。

```

# test/registered/hicache/test_hicache_storage_umbp_backend.py
# DeepSeek-V4 混合 HostPoolGroup 侧池经 UMBP L3 的 round trip 验证。
# 注册为 AMD nightly 专用套件，需要 ROCm + unified_kv_triton 的 DSV4 分支。

```

```

register_amd_ci(
    est_time=3600,
    suite="nightly-amd-8-gpu-mi35x-deepseek-v4-flash",
    nightly=True,
)

```

```

@unittest.skipUnless(is_hip(), "UMBP HiCache requires ROCm.")

```

```

class TestHiCacheStorageUMBPBackend(CustomTestCase):

```

```

    input_ids = list(range(4000, 5024))

```

```

    def test_hybrid_host_pool_round_trip_from_umbp(self):

```

```

        # 先清空设备与宿主缓存，确保第一次请求完全冷启动

```

```

        self._flush_device_and_host_cache()

```

```

        first = self._generate()

```

```

        self.assertEqual(first["meta_info"]["cached_tokens"], 0)

```

```

        # UMBP 写入在请求路径之下是异步的，先等待其落盘，再清缓存

```

```

        time.sleep(15)

```

```

        self._flush_device_and_host_cache()

```

```

        # 第二次请求必须从 UMBP 恢复 side-pool KV，并上报 storage 层命中

```

```

        second = self._generate()

```

```

        cached_details = second["meta_info"].get("cached_tokens_details") or {}

```

```

        storage_cached_tokens = int(cached_details.get("storage", 0))

```

```

        self.assertGreaterEqual(

```

```

            storage_cached_tokens,

```

```

            PAGE_SIZE,

```

```

            f"Expected DeepSeek-V4 side-pool KV to load from UMBP storage, got {cached_details=}"

```

```
        ),
    )
    self.assertEqual(cached_details.get("storage_backend"), "UMBPStore")
```

## 评论区精华

核心讨论有三条：

1) gemini-code-assist 指出 `_register_host_buffer_for_zero_copy` 只处理 `kv_buffer` 单缓冲，`DSAIndexerPoolHost` 等无 `kv_buffer` 的 side pool 会静默退回 staging buffer 路径，作者以代码注释记录 `layer_first` / 多缓冲扩展点，maning00 认为当前不阻塞； 2) gemini-code-assist 建议 `batch_exists_v2` 只查询至 `final_pages` 减少 ZMQ roundtrip，作者在 86aa1e574 中采纳并补回归测试； 3) TianDi101 提出 `hasattr` 防御式写法违反 `no-getattr-defensive` 规则且 4 处重复，作者重构为 `__init__` 一次性初始化、单点计算 `_kv_anchor_is_logical`；另有 `batch_set_v2` 去重冗余的讨论（UMBP 本身去重，已删除）、`extra_info` 未传给 `_batch_io_v2` 导致 `eviction depth` 缺失（maning00 确认当前调用方传 `None`，不阻塞）。hzh0425 要求补 E2E 测试，作者按要求新增 AMD nightly-only 测试。

- 零拷贝注册仅支持 `kv_buffer` 单缓冲 (design): 作者在代码中补充 `NOTE(layer_first)` 注释记录扩展点，maning00 认为当前不阻塞；保留问题。
- `batch_exists_v2` 应只查询至 `final_pages` 减少网络往返 (performance): 作者在 86aa1e574 中采纳并补 4→2→1 收窄回归测试。
- `registered_pools` 与逻辑 `anchor` 判断应单点初始化 (design): 作者重构为 `__init__` 初始化 `registered_pools` / `_kv_anchor_is_logical`，`register_mem_pool_host` 单点计算。
- `batch_set_v2` 未传 `extra_info` 导致 `eviction depth` 缺失 (performance): maning00 确认当前 `hybrid_cache_controller` 调用 `batch_set_v2` 时 `extra_info` 为 `None`，不阻塞；作者未实现 `depth` 传递。
- E2E 测试注册方式与 PR CI 覆盖缺口 (testing): 作者通过 AMD 专用 job（如 `dsv4-umbp-hicache-amd-rocm720`）人工触发验证，测试通过；PR CI 覆盖缺口保留为已知限制。
- `batch_set_v2` 中的重复 `put` 去重是否冗余 (design): 作者删除冗余去重，改为直接 `put`。

## 风险与影响

- 风险： 1) 测试覆盖风险：E2E 测试注册为 `nightly=True` 且经 `register_amd_ci` 限定 `nightly-amd-8-gpu-mi35x-deepseek-v4-flash` 套件，PR CI 从不运行该路径（amd-bot 两次明确警告 "The changed DSv4 multi-pool code is not exercised by any PR-CI test"），且单元测试用 `mocked HostKVCache`； 2) 回归风险：`batch_get_v1` / `batch_set_v1` 对逻辑 `anchor` 直接返回 `[True]`，若未来逻辑 `anchor` 携带物理数据会静默丢数据，当前依赖 `kv_buffer is None` 判断； 3) 零拷贝静默回退：`DSAIndexerPoolHost` 等无 `kv_buffer` 的 side pool 绕过 RDMA 注册走 staging buffer，性能劣化但无报错； 4) `dram_page_size` 留 0 依赖 `mori master` 默认 2 MiB 与 `PoolClient partial-tail` 兜底，size 错配场景依赖外部层； 5) `memory_pool_host.py` 新增 `destroy()` 为无操作，若未来逻辑池持有注册资源需同步扩展。

- 影响：影响范围：AMD (ROCm) HiCache 存储后端链路，使 UMBP (MoRI 分布式内存) 成为 DeepSeek-V4 混合 HostPoolGroup 可用的 L3 后端；用户侧收益：PD 分离场景下 prefill 节点可将 SWA / compressed KV / indexer / state side pool 的 KV offload 到远端 DRAM / SSD, benchmark 显示 1P1D TP8 下 3,779 请求 0 错误、prefix cache hit 97.5%。对团队影响：新增 nightly AMD 套件与 CI 资源占用 (MI35x 8-GPU) ; v2 多池 API 成为 UMBP 后续支持其他混合池模型 (layer\_first 等) 的基座。
- 风险标记：核心存储路径变更，nightly-only 验证，E2E 需 8 块 MI35X, 零拷贝静默回退，PR CI 无法覆盖 DSV4 路径，兼容性依赖 mori 版本

## 关联脉络

- PR #34653 Enable unified cache out-of-window slot freeing by default: 同属统一缓存 (unified cache / SWA 出窗) 演进线，与 DSV4 混合 SWA 的缓存释放策略相关。
- PR #34644 [Fix] Snapshot req.prefix\_indices when the prefix cache is disabled: 同为 kv-cache / scheduling 修复线，涉及 swa\_radix\_cache 与 unified\_radix\_cache。
- PR #34667 Drop the mmlu case from the unified radix cache kit: 同为 hicache / 统一缓存测试基础设施调整，涉及 unified\_radix\_cache\_kit。
- PR #33894 refactor error responses into shared utils::response helpers: 与 PR 的 UMBPStore 重构同属错误处理 / helper 抽取模式，但为 Rust 服务端，关联度较弱。