

PR #28287 完整报告

sgl-project/sglang

[HiCache] Optimize HiCache hash generation with bulk token byte conversion

合并时间: 2026-07-01 15:44

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28287>

执行摘要

- 一句话: 将 HiCache L3 哈希生成从 Python per-token 循环改为 C++ native 扩展, 实现约 70x 加速
- 推荐动作: 值得精读。该 PR 展示了一种典型的热点路径优化模式: 识别 Python 循环瓶颈, 通过 C++ 扩展和 AVX2 指令集大幅加速, 同时保持 Python 调用的便利性。设计决策中关于 per-page scratch buffer 的使用、bigram 重叠对的生成、以及优先利用已有 array 缓冲区避免额外拷贝的思想, 值得在其他性能敏感模块中借鉴。

功能与动机

原有的哈希生成中, 每个 page 的哈希通过 Python 循环 `for t in token_ids:`
`hasher.update(t.to_bytes(4, byteorder="little", signed=False))` 计算, 当 HiCache L3 需要为大量 page 计算哈希时开销很大。该 PR 旨在通过 C++ 原生扩展来消除 per-token Python 调用, 大幅提升哈希生成性能。

实现拆解

1. 新增 C++ 扩展 (hash_binding.cpp): 提供核心哈希例程, 支持 regular 和 bigram 模式, 使用 AVX2 指令加速 uint64 到 uint32 的转换, 并通过 per-page scratch buffer 避免额外内存分配。
2. 新增 Python 包装 (native_hash.py): 检测平台兼容性 (仅支持 little-endian Linux), 通过 `torch.utils.cpp_extension.load` 在运行时编译加载扩展, 提供 `_native_hash_input` 函数预处理输入数据 (支持 array、列表、tuple bigram、EAGLE bigram 等格式), 最终调用 C++ 的 `get_hash` 函数。
3. 重构调用方: 修改 `utils.py` 中的 `get_hash_str` 函数, 新增 `page_size` 参数并委托给 `get_native_hash`; 修改 `radix_cache.py` 中的 `TreeNode.hash_page` 方法, 改为调用 `get_hash_str`; 修改 `cache_controller.py` 和 `hybrid_cache_controller.py` 中的 `_storage_hit_query` 方法, 利用批量哈希批处理减少 Python 循环。
4. 配套测试: 在 `test_mem_cache_utils.py` 中添加了 `_legacy_get_hash_str` 和 `_legacy_page_hashes` 函数作为参考实现, 并通过 `_HashKey` 辅助类构造了多种输入 (plain list、`array('I')`、`array('q')`、bigram 等), 遍历单哈希和页面哈希的兼容性用例, 确保新实现与旧实现输出完全一致。

关键文件:

- python/sglang/srt/mem_cache/cpp_utils/native_hash.py (模块 哈希引擎; 类别 source; 类型 dependency-wiring; 符号 `_cpu_supports_avx2`, `_load_native_hash_module`, `_native_hash_input`, `get_native_hash`) : 新增 Python 包装文件, 负责检测平台兼容性、加载 C++ 扩展并准备输入数据, 是连接 Python 调用方与 C++ 核心的桥梁。
- python/sglang/srt/mem_cache/cpp_utils/hash_binding.cpp (模块 哈希引擎; 类别 source; 类型 dependency-wiring; 符号 `hash_page`, `fill_regular_page`, `fill_bigram_page`, `checked_u32`) : 新增 C++ 核心实现, 包含 SHA256 上下文的复用、per-page scratch buffer 的填充逻辑, 以及 AVX2 优化的 uint64 到 uint32 压缩转换。
- python/sglang/srt/mem_cache/utils.py (模块 缓存工具; 类别 source; 类型 core-logic; 符号 `get_hash_str`) : 核心修改文件, 将原有的 `get_hash_str` 函数替换为委托给 `get_native_hash`, 并新增 `page_size` 参数以支持批量页面哈希计算。
- python/sglang/srt/mem_cache/radix_cache.py (模块 Radix 缓存; 类别 source; 类型 dependency-wiring; 符号 `TreeNode.hash_page`) : 修改了 `TreeNode.hash_page` 方法, 由原来的内联 SHA256 改为调用 `get_hash_str`, 并移除了直接的 hashlib 依赖。
- python/sglang/srt/managers/cache_controller.py (模块 缓存控制器; 类别 source; 类型 entrypoint; 符号 `CacheController._storage_hit_query`) : 修改了 `_storage_hit_query` 方法, 将原先的内部循环批量查询改为一次性调用 `get_hash_str(page_size=...)` 获取所有页面哈希后再切片处理, 减少了 Python 循环。
- python/sglang/srt/mem_cache/hybrid_cache/hybrid_cache_controller.py (模块 混合缓存; 类别 source; 类型 entrypoint) : 类似 `cache_controller.py`, 更新了混合缓存的哈希查询路径, 使用新的批量哈希接口。
- test/registered/unit/mem_cache/test_mem_cache_utils.py (模块 测试; 类别 test; 类型 test-coverage; 符号 `TestGetEvictionStrategy`, `_legacy_get_hash_str`, `_legacy_page_hashes`, `_HashKey`) : 大幅扩展的测试文件, 新增了 `_legacy_get_hash_str`、`_legacy_page_hashes` 参考实现和 `_HashKey` 辅助类, 覆盖了多种输入格式的兼容性验证。

关键符号: `get_hash_str`, `get_native_hash`, `_native_hash_input`, `TreeNode.hash_page`, `CacheController._storage_hit_query`, `compute_node_hash_values`

评论区精华

review 主要由 `gemini-code-assist[bot]` 提出两条中等优先级建议:

1) 使用 `Union[str, List[str]]` 代替 `str | List[str]` 以兼容 Python <3.10; 2) 使用 `itertools.chain.from_iterable` 优化嵌套生成器。但这两个建议未被作者采纳, 最终 PR 仍保留了 `str | List[str]` 和嵌套生成器写法, 由 `xiezhq-hermann` 批准合并。

- 关于 Python 版本兼容性使用 Union 的建议 (style): 作者未采纳建议, PR 仍保留 `str | List[str]` 和嵌套生成器写法, 由 `xiezhq-hermann` 批准合并。

风险与影响

- 风险: 1) C++ 扩展依赖 OpenSSL 的 `-lcrypto` 及 `pybind11`, 在国内环境或某些 Docker 镜像下可能导致编译失败。2) 仅支持 little-endian Linux 系统, 其他平台 (如 macOS、Windows) 会抛出 `RuntimeError`。3) 哈希算法虽然逻辑一致, 但新实现必须保证与旧实现

的精确输出一致，以免导致缓存 miss 或数据不一致。测试中已通过_legacy_get_hash_str 进行了兼容性验证，但生产环境下仍可能存在边缘 case。 4) 新扩展通过 torch.utils.cpp_extension.load 在运行时编译，可能引入首次调用时的延迟。

- 影响：直接提升 HiCache L3 哈希生成性能约 70x，降低缓存查询开销。对系统其余部分无影响。所有调用方均在内部委托给新实现，对外 API 保持向后兼容（get_hash_str 新增了可选参数 page_size）。测试覆盖了单页面哈希和批量页面哈希的兼容性。
- 风险标记：编译依赖 OpenSSL/pybind11，仅限 little-endian Linux，首次编译延迟，哈希一致性需验证

关联脉络

- 暂无明显关联 PR