

PR #36308 完整报告

sgl-project/sglang

[AMD][CI] Limit HiCache MGSM eval concurrency on ROCm

合并时间: 2026-08-28 16:06

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36308>

执行摘要

- 一句话: 限制 ROCm 上 HiCache MGSM 评估并发
- 推荐动作: 值得快速浏览, 作为针对特定硬件环境的测试参数调整示例。关注点: 使用条件属性覆盖默认值, 保持非 HIP 行为不变, 最小化改动。无需深入精读。

功能与动机

ROCm 7.2.4 MI300 的 CI 任务 `stage-b-test-1-gpu-small-amd-rocm720 (4)` 中, `TestHiCacheMLA.test_mgsm_en` 重试后得分分别为 0.564 和 0.612, 低于 0.8 的阈值。PR 说明指出, MGSM 英文包含 250 个示例, 而 `MGSMEnMixin` 默认使用 1024 个客户端线程, 导致整个评估并发提交, 失败任务达到 250 个运行中请求。这是一个 HiCache 准确率集成测试而非最大并发压力测试, 因此本 PR 旨在限制 AMD 测试负载, 而不降低准确率要求。

实现拆解

1. 修改测试类配置: 在 `test/registered/hicache/test_hicache_variants.py` 的 `TestHiCacheMLA` 类中, 新增条件属性定义: 当 `_is_hip` 为真时, 设置 `mgsm_en_num_threads = 32`; 非 HIP 环境不定义该属性, 从而继承 `MGSMEnMixin` 的默认值 (1024)。
2. 保持准确率逻辑不变: 未修改 `mgsm_en_score_threshold` (仍为 0.8), 也未调整其他测试逻辑, 仅通过降低并发线程数来减少同时运行的请求数, 从而避免因并发过高导致的准确率下降。
3. 验证: 在受影响的 ROCm 7.2.4 MI300 part 4 任务中验证通过, 得分 0.872 (阈值 0.8), 最大 decode 批次从 250 降至 32, 完整测试文件耗时 1961 秒, 低于 2400 秒超时。

关键文件:

- `test/registered/hicache/test_hicache_variants.py` (模块 测试配置; 类别 test; 类型 test-coverage): 唯一的变更文件, 在 `TestHiCacheMLA` 类中为 HIP 环境添加 `mgsm_en_num_threads=32`, 以限制并发线程数, 解决 ROCm 测试准确率不达标问题。

关键符号: 未识别

关键源码片段

`test/registered/hicache/test_hicache_variants.py`

唯一的变更文件，在 TestHiCacheMLA 类中为 HIP 环境添加 mgsm_en_num_threads=32，以限制并发线程数，解决 ROCm 测试准确率不达标问题。

```
class TestHiCacheMLA(HiCacheBaseServer, MMLUMixin, MGSMEnMixin):
    """HiCache with MLA model tests"""

    model_name = DEFAULT_MLA_MODEL_NAME_FOR_TEST
    hicache_args = [
        "--trust-remote-code",
        "--enable-hierarchical-cache",
    ] + ([ "--hicache-size", 200 ] if _is_hip else [ "--hicache-ratio", 2 ])
    mmlu_score_threshold = 0.54
    mmlu_num_examples = 256
    mmlu_num_threads = 32
    mgsm_en_score_threshold = 0.8
    # 仅 HIP 环境限制 MGSM 评估的客户端线程数，降低并发压力，
    # 避免因并发过高导致准确率下降。非 HIP 环境继承默认值。
    if _is_hip:
        mgsm_en_num_threads = 32
```

评论区精华

无 review 评论。审核人 HaiShaw 直接批准 (APPROVED)。

- 暂无高价值评论线程

风险与影响

- 风险：风险较低。改动仅限测试文件，不涉及生产代码。主要风险是降低并发可能影响测试对高并发场景的覆盖，但该测试定位为准确率集成测试而非压力测试。此外，如果 ROCm 环境（如 MI300）的并发限制值 32 在其他模型或配置下不适用，可能导致测试通过但未覆盖真实负载，但影响有限。
- 影响：影响范围限于 CI 测试：ROCm 上的 HiCache MLA 测试并发度降低，可能减少偶发失败，提高 CI 稳定性。对生产代码无影响。对团队而言，减少了 ROCm CI 的 flaky 失败，节省排查时间。
- 风险标记：仅测试变更，风险低

关联脉络

- PR #35931 [HiCache] Reject load-back specs that claim nodes pinned by an in-flight load-back: 同为 HiCache 相关稳定性修复，针对调度器崩溃，与本 PR 同在 HiCache 测试域。
- PR #36227 [HiCache] Retry L3 storage prefetch after a missed attempt: 同为 HiCache 相关优化，调整调度器预取逻辑，可能影响测试行为。
- PR #36705 [HiCache] Stop populating host-pool mmmaps twice (-13% allocation time): 同为 HiCache 性能修复，涉及内存分配器，可能与并发测试相关。