

PR #51174 完整报告

vllm-project/vllm

[ROCm] Work around DeepEP teardown SIGSEGV in MoE test harness

合并时间: 2026-08-06 03:44

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/51174>

执行摘要

- 一句话: ROCm 下 DeepEP 测试 teardown SIGSEGV 的 workaround
- 推荐动作: 该 PR 改动小而聚焦, 但提交信息中的根因分析 (ROCr Runtime::Unload() 与 GpuAgent::ReleaseResources() 之间的 use-after-free) 值得阅读, 可作为理解 HIP teardown 时序的案例。适合关注 ROCm 测试稳定性的工程师精读; 对于一般读者, 了解其 workaround 思路即可, 不建议作为长期方案。

功能与动机

PR body 明确说明: 在 ROCm 上 `test_deep_ep_moe` 每个 rank 以 SIGSEGV 退出, 且无 traceback; MoE 计算正确, 崩溃是 teardown 阶段的 ROCr use-after-free (存在于 HIP 的 atexit handler, 上游修复见 <https://github.com/ROCm/rocm-systems/pull/6942>)。需要在不改变计算逻辑的前提下, 让测试能正确报告通过 / 失败信号, 同时不影响非 ROCm 平台。

实现拆解

1. 在测试 worker 中引入平台检测: `tests/kernels/moe/parallel_utils.py` 新增 `from vllm.platforms import current_platform` 导入, 用于在运行时判断是否为 ROCm 平台。
2. 跟踪 worker 退出码: 在 `_worker_parallel_launch` 中新增局部变量 `exit_code = 0`; 当 worker 抛出异常时, 打印异常和 traceback 后置 `exit_code = 1`, 再 `raise` 以便父进程能捕获异常详情。
3. 在 `finally` 块中针对 ROCm 强制退出: 在 `torch.distributed.destroy_process_group()` 之后, 若 `current_platform.is_rocm()` 为真, 则依次 `sys.stdout.flush()`、`sys.stderr.flush()` 后调用 `os._exit(exit_code)`。这样绕过 HIP atexit 处理器中的 use-after-free, 同时保留 flush 后的 traceback 输出和退出码语义。
4. 后续移除标记: 代码中留有 TODO (Rohan138): Remove after ROCm 10.0 lands, 并注释了上游修复 PR 链接, 便于基础镜像更新后回退。
5. 无生产代码改动: 变更仅涉及测试工具函数, `parallel_launch` 的对外接口不变, 非 ROCm 平台行为与之前完全一致。

关键文件:

- `tests/kernels/moe/parallel_utils.py` (模块 测试工具; 类别 test; 类型 test-coverage; 符号 `_worker_parallel_launch`): 该文件是 DeepEP MoE 测试的并行启动工具, 本次变更在 `_worker_parallel_launch` 的 `finally` 块中针对 ROCm 平台引入 `os._exit` 绕过 teardown

阶段的 SIGSEGV, 是 PR 唯一改动的文件, 集中体现了 workaround 的全部逻辑。

关键符号: `_worker_parallel_launch`

关键源码片段

`tests/kernels/moe/parallel_utils.py`

该文件是 DeepEP MoE 测试的并行启动工具, 本次变更在 `_worker_parallel_launch` 的 `finally` 块中针对 ROCm 平台引入 `os._exit` 绕过 `teardown` 阶段的 SIGSEGV, 是 PR 唯一改动的文件, 集中体现了 workaround 的全部逻辑。

```
def _worker_parallel_launch(
    local_rank: int,
    world_size: int,
    world_local_size: int,
    node_rank: int,
    init_method: str,
    worker: Callable[[Concatenate[ProcessGroupInfo, P], None],
    *args: P.args,
    **kwargs: P.kwargs,
) -> None:
    rank = node_rank * world_local_size + local_rank
    torch.accelerator.set_device_index(local_rank)
    device = torch.device("cuda", local_rank)
    torch.distributed.init_process_group(
        backend="nccl",
        init_method=init_method,
        rank=rank,
        world_size=world_size,
    )
    barrier = torch.tensor([rank], device=device)
    torch.distributed.all_reduce(barrier)

    exit_code = 0
    try:
        worker(
            ProcessGroupInfo(
                world_size=world_size,
                world_local_size=world_local_size,
                rank=rank,
                node_rank=node_rank,
                local_rank=local_rank,
                device=device,
            ),
            *args,
            **kwargs,
        )
    except Exception as ex:
        print(ex)
```

```
traceback.print_exc()
exit_code = 1 # 标记失败, 用于 os._exit 传递退出码
raise
finally:
    torch.distributed.destroy_process_group()
    if current_platform.is_rocm():
        # 绕过 ROCm teardown use-after-free (HIP atexit handler 中的 SIGSEGV,
        # 上游修复见 https://github.com/ROCm/rocm-systems/pull/6942) 。
        # 先 flush 再 os._exit, 因为 os._exit 跳过缓冲刷新, 以保留失败 traceback。
        # TODO (Rohan138): Remove after ROCm 10.0 lands
        sys.stdout.flush()
        sys.stderr.flush()
        os._exit(exit_code)
```

评论区精华

该 PR 的 review 评论很少: [claude\[bot\]](#) 自动回复说明 fork PR 不启用自动 review; maintainer [AndreasKaratzas](#) 直接批准 (LGTM), 无实质技术辩论。技术决策已在 PR body 和提交信息中充分阐述, 没有遗留的未解决疑虑。

- 暂无高价值评论线程

风险与影响

- 风险: 风险集中在测试工具层面, 不触及生产代码:
 1. `os._exit` 跳过清理: 会绕过 Python 和第三方库的退出钩子, 可能导致某些资源 (如 NCCL communicator、文件句柄) 未释放, 但该行为仅发生在 ROCm 平台且仅用于测试进程, 影响有限。
 2. 异常信号传播: `raise` 与 `os._exit` 组合可能使父进程无法看到原始 traceback (已通过 flush 缓解), 且 `exit_code` 仅区分 0/1, 无法传递具体异常类型, 但足以判断测试通过与否。
 3. 平台判断依赖: `current_platform.is_rocm()` 在非 ROCm 环境为 `false`, 行为不变, 但若未来平台判断逻辑变更需同步关注。
 4. 上游依赖: 若基础镜像提前包含 ROCm 修复, 该 workaround 仍会生效 (`os._exit` 无害), 但会造成不必要的 teardown 跳过, 需按 TODO 及时移除。- 影响: 影响范围限定在 `tests/kernels/moe/test_deepest_moe.py` 及相关 MoE 测试的 ROCm 运行环境: 此前的 28 个失败用例 (每个 rank SIGSEGV) 将全部转为通过, 显著提升 ROCm CI 的稳定性和可观测性。对生产推理代码、非 ROCm 平台、其他测试无影响。团队收益是减少 CI 噪音, 并提供了清晰的 root cause 文档, 便于后续移除 workaround。- 风险标记: 测试环境 workaround, `os._exit` 跳过清理, 依赖上游修复

关联脉络

- PR #51173 [ROCm][CI] Keep rocprofiler-sdk out of DeepEP HT MoE test workers: 同为 DeepEP MoE 测试在 ROCm 下的 CI 稳定性修复, 与本 PR 修改同一测试文件 (`tests/kernels/moe/parallel_utils.py` 被 #51173 间接关联), 二者共同解决 ROCm 环境下

的测试崩溃类问题。