

# PR #47003 完整报告

vllm-project/vllm

[ROCm][CI] Use spawn around the threaded OTLP test

合并时间: 2026-06-30 05:34

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47003>

## 执行摘要

- 一句话: ROCm CI OTLP 测试改用 spawn 并清理资源
- 推荐动作: 推荐阅读该 PR, 它展示了如何处理 fork 与 gRPC 线程冲突的典型方法: 通过检测平台切换到 spawn 模式, 并注重资源释放。对于在其他平台需类似调整的场景有参考价值。

## 功能与动机

PR body 指出: 测试启动 fake OTLP/gRPC 后父进程已有 gRPC 工作线程, 当 vLLM 通过 fork 启动 engine worker 时, 该 fork 模式在 ROCm CI 上可能导致 engine 启动或关闭时 segfault。PR 的目标是测试 span 导出行为, 而非 multiprocessing 启动模式, 因此在 ROCm 上改用 spawn。

## 实现拆解

1. 导入新模块: 在 tests/v1/tracing/test\_tracing.py 文件顶部添加 from vllm.distributed import cleanup\_dist\_env\_and\_memory 和 from vllm.platforms import current\_platform。
2. 平台条件判断: 在 test\_traces 函数中, 使用 current\_platform.is\_rocm() 判断当前是否为 ROCm 平台, 若是则设置环境变量 VLLM\_WORKER\_MULTIPROC\_METHOD=spawn, 避免 gRPC 线程活跃时 fork。
3. 生命周期管理: 将 LLM 的创建和使用放入 try 块, finally 块中检查引擎是否已创建, 若是则调用 llm.llm\_engine.engine\_core.shutdown(timeout=...) 显式关闭; 对于 ROCm, timeout 设为 60 秒以应对可能的延迟。
4. 清理分布式环境: 在 finally 中调用 cleanup\_dist\_env\_and\_memory() 释放分布式相关资源, 确保测试结束后环境干净。

关键文件:

- tests/v1/tracing/test\_tracing.py (模块 追踪; 类别 test; 类型 test-coverage; 符号 test\_traces): 唯一被修改的文件, 包含所有针对 ROCm 测试稳定性的修正。

关键符号: test\_traces

## 关键源码片段

[tests/v1/tracing/test\\_tracing.py](#)

唯一被修改的文件，包含所有针对 ROCm 测试稳定性的修正。

```
# 设置 spawn 模式 (ROCM 专用)
if current_platform.is_rocm():
    m.setenv('VLLM_WORKER_MULTIPROC_METHOD', 'spawn')

model = 'facebook/opt-125m'
llm = None
try:
    llm = LLM(
        model=model,
        gpu_memory_utilization=0.3,
        disable_log_stats=False,
    )
    # 生成并验证 span 属性 (省略具体断言)
finally:
    if llm is not None:
        # ROCm 平台使用更长 timeout
        shutdown_timeout = 60.0 if current_platform.is_rocm() else 5.0
        llm.llm_engine.engine_core.shutdown(timeout=shutdown_timeout)
    cleanup_dist_env_and_memory()
```

## 评论区精华

- Reviewer: yewentao256 针对 shutdown 的 timeout 长度提出疑问: "Should this be longer?", 担心 ROCm 上的关闭操作可能需要更多时间。
- Author: AndreasKaratzas 回应并增加 ROCm 专属的 shutdown timeout 至 60 秒 (非 ROCm 保持 5 秒), 解决了该疑虑。
- 最终 reviewer 批准 PR。
- ROCm shutdown timeout 是否需要更长 (question): 作者将 ROCm 的 shutdown timeout 调整为 60 秒, 非 ROCm 保持 5 秒。

## 风险与影响

- 风险:
  - 低风险: 变更仅涉及单测试文件, 且所有平台特定逻辑通过 `current_platform.is_rocm()` 隔离, 不影响其他平台。
  - 可能的故障: 若 shutdown timeout 60 秒仍不足, 测试可能 timeout, 但远超实际需要, 风险较低。
  - 无产品代码影响: 改动全部在测试目录下, 不涉及任何生产路径。
- 影响:
  - 对用户: 无直接影响。
  - 对系统 / CI: 消除 ROCm CI 上一个已知的 flaky segfault, 提升测试可靠性。
  - 对团队: 报告预期更少的误报失败, 减少人工重试; 代码模式可复用。
  - 风险标记: 仅测试变更, 平台特定修复, 低风险

# 关联脉络

- 暂无明显关联 PR