

PR #43154 完整报告

vllm-project/vllm

[Core][AMD] Propagate shutdown timeout to MultiprocExecutor

合并时间: 2026-06-13 04:13

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/43154>

执行摘要

- 一句话: 新增 `VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS` 环境变量, 可配置关闭超时, 默认 5 秒。
- 推荐动作: 本 PR 改动量小但设计思路清晰, 展示了 vLLM 中新增可配置超时的典型模式: 通过 `envs.py` 定义环境变量, 在核心关闭路径处引用。特别值得关注的是 njhill 对 `shutdown_timeout` 不同语义的区分 — worker 关闭超时与全局优雅关闭是不同概念。建议读者关注 `_ensure_worker_termination` 和 `BackgroundResources.__call__` 两处修改, 以理解 shutdown 流程中超时的传递链路。

功能与动机

rocprofv3 需要一段优雅期在进程关闭时发出 trace 数据, 而 `MultiprocExecutor` 中原来的 4 秒固定超时不足以完成这一操作, 导致跟踪命令失败。PR body 中说明了这一场景, 并在 Review 中由 njhill 指出 `config.shutdown_timeout` 语义不同, 建议使用独立环境变量控制 worker 关闭超时。

实现拆解

1. 在 `vllm/envs.py` 中声明环境变量: 添加 `VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS` 字段 (类型 `int`, 默认值 5), 并在 `_get_envs` 字典中提供解析函数, 从环境变量读取或回退到 5。
2. 修改 `multiproc_executor.py` 中的 worker 终止逻辑: 在 `_ensure_worker_termination` 方法中, 将 `wait_for_termination(active_procs(), 4)` 改为读取 `envs.VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS`, 使等待超时可配置。
3. 修改 `core_client.py` 中的 `BackgroundResources.__call__`: 在调用 `engine_manager.shutdown()` 时传入 `timeout=envs.VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS`, 确保核心引擎关闭也沿用同一变量。
4. 添加单元测试:
 - `test_executor.py`: 引入 `_FakeClock` 和 `_FakeProcess` 模拟时间流逝, 通过参数化验证 worker 在超时前退出时不会调用 `terminate`, 超时后会调用。
 - `test_core_engine_actor_manager.py`: 模拟 `BackgroundResources` 调用, 验证它是否以正确的 `timeout` 参数调用 `engine_manager.shutdown`。

关键文件:

- `vllm/envs.py` (模块 环境配置; 类别 `source`; 类型 `core-logic`) : 新增环境变量声明和运行时解析, 是配置入口。
- `vllm/v1/executor/multiproc_executor.py` (模块 执行器; 类别 `source`; 类型 `core-logic`) : 核心变更: 将 `worker` 终止等待超时从硬编码改为读取环境变量, 使关闭延迟可配置。
- `vllm/v1/engine/core_client.py` (模块 引擎客户端; 类别 `source`; 类型 `dependency-wiring`) : 将环境变量超时传递给 `engine_manager.shutdown`, 确保核心引擎关闭使用同一配置。
- `tests/v1/executor/test_executor.py` (模块 执行器测试; 类别 `test`; 类型 `test-coverage`; 符号 `_FakeClock, init, time, sleep`) : 覆盖 `worker` 终止超时逻辑的两种场景 (超时前退出和超时后终止) 。
- `tests/v1/engine/test_core_engine_actor_manager.py` (模块 引擎测试; 类别 `test`; 类型 `test-coverage`; 符号 `test_background_resources_passes_worker_shutdown_timeout`) : 验证 `BackgroundResources` 将环境变量超时正确传递给 `engine_manager.shutdown`。

关键符号: `_ensure_worker_termination`, `BackgroundResources.call`,
`test_multiproc_executor_worker_termination_timeout`,
`test_background_resources_passes_worker_shutdown_timeout`

关键源码片段

`vllm/v1/executor/multiproc_executor.py`

核心变更: 将 `worker` 终止等待超时从硬编码改为读取环境变量, 使关闭延迟可配置。

```
# vllm/v1/executor/multiproc_executor.py ( 关键片段 )
# 在 `_ensure_worker_termination` 方法中, 原超时固定为 4 秒,
# 现改为从环境变量 VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS 读取 (默认 5 秒) 。
```

```
def _ensure_worker_termination(self, worker_procs):
    # ... 前面逻辑 ...
    active_procs = lambda: [proc for proc in worker_procs if proc.is_alive()]
    logger.debug("[shutdown] Executor: waiting for worker exit count=%d", initial_count)
    # 使用可配置超时, 默认为 5 秒
    if wait_for_termination(
        active_procs(), timeout=envs.VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS
    ):
        logger.info_once("[shutdown] Executor: all workers exited gracefully")
        return
    # 如果超时, 继续强制终止 ...
```

`vllm/v1/engine/core_client.py`

将环境变量超时传递给 `engine_manager.shutdown`, 确保核心引擎关闭使用同一配置。

```
# vllm/v1/engine/core_client.py (BackgroundResources.__call__ 片段 )
# 当资源清理时, 将可配置超时传递给引擎管理器。
```

```
def __call__(self):
    logger.debug_once("[shutdown] MPPClient: background resource cleanup start")
    self.engine_dead = True
```

```
if self.engine_manager is not None:
    # 传入从环境变量读取的超时，默认为 5 秒
    self.engine_manager.shutdown(
        timeout=envs.VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS
    )
if self.coordinator is not None:
    self.coordinator.shutdown()
# 后续关闭 socket 等 ...
```

评论区精华

- 使用环境变量 vs 复用 config 字段: njhill 指出 `vllm_config.shutdown_timeout` 原本用于全局优雅关闭（等待在途请求完成），而 worker 关闭是 tear-down 后的快速终止，语义不同，建议新增独立环境变量 `VLLM_WORKER_SHUTDOWN_TIMEOUT_SECONDS`。rjrock 接受了此建议并重构代码。
- 默认值选择: 初始 PR 设为 4（与原来硬编码一致），但 njhill 建议改为 5，因为核心引擎的默认关闭超时原本就是 5，最终采纳改为 5。
- 最小超时保证的移除: rjrock 在评论中指出，本 PR 最初引用了一个 `max(shutdown_timeout, 4)` 保护逻辑，但该逻辑已在 PR #43016 中被移除，因此本次改用环境变量也避免了可能传入 0 或 `None` 的问题。
 - 使用独立环境变量而非 `vllm_config.shutdown_timeout` (design): 最终采用新环境变量，并在 `multiproc_executor.py` 和 `core_client.py` 中使用。
 - 默认值从 4 改为 5 (design): 默认值改为 5，与核心引擎保持一致。
 - `shutdown_timeout` 可能为 `None` 或 0 的问题 (correctness): 改用环境变量后，不存在 `None` 问题，安全性提升。

风险与影响

- 风险:
 - 对默认用户的影响: 默认超时从 4 秒变为 5 秒，轻微增加关闭等待时间，一般不会造成问题，但在 CI 或快速销毁场景可能略有延迟。
 - 环境变量未设置时行为: 默认值 5 通过代码设定，不会为 `None`，因此无 `TypeError` 风险。但用户若设置极小的值（如 0），可能导致 worker 几乎立即被终止，无法正常释放资源。建议文档提示合理范围。
 - 仅影响 `MultiprocExecutor`: 该环境变量仅在使用 `MultiprocExecutor`（`TP > 1`）时生效，对 `UniProcExecutor` 无影响，限定在分布式推理场景。
- 影响:
 - 用户影响: 仅对使用 `rocmprofv3` 等需要更长关闭超时的 profiling 用户是积极改善；对其他用户影响极小（默认值从 4 变 5），无需适配。
 - 系统影响: 关闭超时可配置意味着极端情况下进程可能挂起更久，但不会影响推理性能。
 - 团队影响: 新增环境变量，需要维护文档和向后兼容。但变量命名符合已有风格，易于理解。
 - 风险标记: 核心路径变更，默认行为变更

关联脉络

- 暂无明显关联 PR