

PR #28089 完整报告

sgl-project/sglang

[CI] Reclaim leaked /dev/shm segments on server startup

合并时间: 2026-06-16 07:14

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28089>

执行摘要

- 一句话: CI 启动时自动清理泄漏的共享内存段
- 推荐动作: 值得精读, 尤其是其降级策略设计: 通过命名嵌入 PID、仅 CI 激活、最佳努力清理不阻塞启动等。可作为容器中资源泄漏处理的参考模式。建议开发者和基础设施维护者关注 `cleanup_stale_shm` 的门控机制和异常处理模式。

功能与动机

CI job 中通过 `kill_process_tree` 和 `PR_SET_PDEATHSIG` 以 `SIGKILL` 终止进程, 跳过了所有 Python 级别的共享内存清理路径 (`finally`、`atexit`、`multiprocessingresource_tracker` 等)。泄漏的 `psm_*` 段在长期运行的 runner 容器中累积, 直到 `/dev/shm` (1-GPU runner 上仅 1 GiB) 100% 占满, 导致下一个调度器初始化时出现 'Fatal Python error: Bus error' 崩溃。实际在 `h100-novita-host3-gpu-2` 上观察到 `base-b-test-1-gpu-large` 失败, `/dev/shm` 被数百个多 MB 段填满。

实现拆解

1. 新增 `stale_shm_cleanup` 模块(`python/sglang/srt/Utils/stale_shm_cleanup.py`): 定义 `make_shm_name(kind)` 生成 `sgl_shm_<kind>_<pid>_<rand>` 格式的段名; 实现 `cleanup_stale_shm()` 遍历 `/dev/shm`, 对匹配段提取 PID 并通过 `os.kill(pid,0)` 判断进程是否存活, 若已死则 `unlink`; 所有操作以 `SGLANG_IS_IN_CI` 环境变量为门控 (仅 CI 容器设置), 异常容错绝不阻塞启动。
2. 改造四个匿名 SharedMemory 创建点: 在 `ShmRingBuffer` (`shm_broadcast.py`)、`in_the_same_node_as` (`parallel_state.py`)、`ShmPointerMMData` (`mm_utils.py`)、`ShmSyncBuffer` (`cuda_ipc_transport_utils.py`) 的 `SharedMemory(create=True)` 调用中增加 `name=make_shm_name(...)` 参数, 使这些段遵循可回收命名规范。
3. 集成到 CI 脚本: 在 `ci_install_dependency.sh` 中 (`kill_existing_processes` 之后、依赖安装之前) 通过 `python path/to/module.py` 执行清扫模块。此时 `sglang` 尚未安装, 该模块保持 `import-free` 且可通过 `__main__` 入口运行。
4. 添加完整单元测试: 新建 `test_stale_shm_cleanup.py`, 包含名称格式、PID 解析、清扫场景 (清理死段、保留活段、不碰外来段)、CI 外无操作、生产绑定 (`ShmRingBuffer` 名称校验)、离线路径执行等 7 个测试用例, 注册到 CPU CI suite。

关键文件:

- python/sglang/srt/utlis/stale_shm_cleanup.py (模块 共享内存清扫; 类别 source; 类型 core-logic; 符号 make_shm_name, _creator_pid, _pid_alive, cleanup_stale_shm) : 核心新模块: 定义共享内存命名规则与清扫逻辑, 是本次变更的核心实现。
- test/registered/utlis/test_stale_shm_cleanup.py (模块 单元测试; 类别 test; 类型 test-coverage; 符号 _spawn_dead_pid, TestMakeShmName, test_embeds_pid_and_is_unique, test_creator_pid_parsing) : 完整单元测试覆盖: 包括命名解析、场景测试 (清理 / 不清理 / 不误删)、生产站点绑定测试、离线执行测试等
- python/sglang/srt/distributed/device_communicators/shm_broadcast.py (模块 通信层; 类别 source; 类型 dependency-wiring) : ShmRingBuffer 创建点改造: 传入 name=make_shm_name('mq') 使共享内存段可被回收
- python/sglang/srt/distributed/parallel_state.py (模块 并行状态; 类别 source; 类型 dependency-wiring) : in_the_same_node_as 函数创建点改造: 传入 name=make_shm_name('nodecheck') 使其可回收
- python/sglang/srt/managers/mm_utils.py (模块 MM 工具; 类别 source; 类型 dependency-wiring) : ShmPointerMMData 创建点改造: 传入 name=make_shm_name('mm') 使其可回收
- python/sglang/srt/utlis/cuda_ipc_transport_utils.py (模块 IPC 传输; 类别 source; 类型 dependency-wiring) : ShmSyncBuffer 创建点改造: 传入 name=make_shm_name('sync') 使其可回收
- scripts/ci/cuda/ci_install_dependency.sh (模块 CI 脚本; 类别 infra; 类型 infrastructure) : CI 脚本集成清扫调用: 在 job 开始时运行 cleanup_stale_shm 模块

关键符号: make_shm_name, _creator_pid, _pid_alive, cleanup_stale_shm, _is_in_ci, _cleanup_stale_shm_impl, in_the_same_node_as, ShmRingBuffer, ShmPointerMMData, ShmSyncBuffer

评论区精华

PR 页面无公开审核评论, 但从 commit 信息 “address review: crash-proof sweep, log failures, cover remaining anonymous shm sites” 可以推断, 评审中重点关注了: (1) 清扫失败不应阻塞服务器启动 (最终实现最外层 try/except + logging.warning); (2) 失败日志应记录而非静默忽略; (3) 所有匿名共享内存站点都应被覆盖。PR 描述也明确包含了设计原则: CI-only、Best-effort、PID 重用降级为少清理而非误删。

- 清扫失败不应阻塞启动 (design): 已实现: cleanup_stale_shm() 不抛出异常, 失败仅记录 warning。
- PID 重用导致漏清理的设计接受 (design): 接受退化, 维持安全偏向。

风险与影响

- 风险:
 - PID 重用风险: 死进程的 PID 可能被新进程重用, 此时 _pid_alive 返回 True 导致对应段不被清理。设计接受此退化: 最多漏清理, 不会误删。

- CI 环境假阳性：若用户在非 CI 环境设置 `SGLANG_IS_IN_CI=true` 并运行，可能误清理其他用户段。但实际该变量仅在 CI 容器内由系统设置，共享机器上用户通常不会设置。
- `/dev/shm` 不存在：代码已判断 `is_dir()`，不会异常。
- 清扫全异常捕获：`cleanup_stale_shm` 外层捕获所有异常，不会阻止启动。
- 对生产环境无影响。
- 影响：直接影响 CI runner 可靠性：新 job 启动时会自动清理遗留共享内存段，预计可消除因 `/dev/shm` 满导致的 CI 失败，减少假阳性，提升 CI 稳定性。对用户无感知，对系统架构无侵入。
- 风险标记：仅 CI 适用，PID 重用退化，最佳努力清扫

关联脉络

- 暂无明显关联 PR