

PR #36180 完整报告

sgl-project/sglang

[npu] Combine NPU test fixes from #35472 and #34516

合并时间: 2026-08-25 09:00

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36180>

执行摘要

- 一句话: 合并 NPU 测试修复: 进程组收割与挂起检测
- 推荐动作: 值得 NPU 测试维护者精读 `run_bench_serving` 的看门狗实现: 把 'stdout 空转超时 + 排空宽限 + 进程组 SIGKILL' 组合起来管理长跑子进程, 是一个可复用的测试进程治理模式。一般开发者可略读, 只需关注 `DEEPEP_HCCL_BUFFSIZE` 这类环境变量约定是否与本仓库 NPU 部署文档一致。

功能与动机

PR body 明确动机: Improve reliability of Ascend NPU benchmark and accuracy tests by detecting hung benchmark processes earlier and cleaning up orphaned process groups. 此前 benchmark 进程一旦挂起会一直占住 stdout, CI 只能等到全局超时; 而 deep-ep / HCCL 的 worker 进程在父进程退出后会被 reparent, 遗留为孤儿进程, 污染同一 runner 上的后续测试。作者把 #35472、#34516 两个修复整合到主线, 消除重复实现并统一进程组清理逻辑。

实现拆解

1. 新增 `kill_process_group` 进程组收割工具 (`python/sglang/test/ascend/e2e/test_npu_multi_node_utils.py`): 基于 `start_new_session` 进程模型, 用 `os.killpg(process.pid, signal.SIGKILL)` 收割整个进程组, 分场景处理 `ProcessLookupError`、`PermissionError` 与 `OSError`, 作为 NPU 测试套件的统一清理入口, 供 `perf` 与 `accuracy` 两侧复用。
2. 重写 `run_bench_serving` 的看门狗 (`python/sglang/test/ascend/e2e/test_npu_performance_utils.py`): `benchmark` 子进程改为 `start_new_session=True` 启动; 新增常量 `BENCHMARK_STDOUT_DRAIN_GRACE` (10 秒)、`BENCHMARK_STDOUT_IDLE_TIMEOUT` (300 秒)、`BENCHMARK_WATCHDOG_POLL_INTERVAL` (30 秒); 守护线程 `_kill_on_timeout` 覆盖三种僵死场景 (直接子进程退出但 stdout 被孙进程持有、stdout EOF 但子进程不退出、长时间无输出疑似挂起), 统一走 `kill_process_group` 强杀; 读线程逐行消费 stdout 并刷新 `last_activity` 标量供 watchdog 判断。
3. `accuracy` 清理统一 (`python/sglang/test/ascend/e2e/test_npu_accuracy_utils.py`): 删除本地重复的 `_kill_evalscope_session` 与 `signal` 导入, 在 `run_evalscope` 的正常、异常与超时路径统一调用 `kill_process_group`, 避免两套收割逻辑漂移。

4. 测试配置与类名修正: qwen3_vl_8b_thinking 与 qwen3_vl_30b_a3b_thinking 两个 MMMU 测试把 HCCL_BUFFSIZE 改名为 DEEPEP_HCCL_BUFFSIZE (对齐 deep-ep 的新环境变量约定), 类名从 TestQwen3 改为带模型语义的 TestQwen3_VL_8B_Thinking_MMMU / TestQwen3_VL_30B_A3B_Thinking_MMMU, 并把 8B 的 nightly est_time 从 6500 提升到 12000; kimi_k2_6 性能测试增加 --max-total-tokens 32256 参数。
5. CI workflow 调整 (.github/workflows/pr-test-npu.yml) : base-c-test-acc 四个 stage 的 runner 标签从 linux-aarch64-a3- 切换为 linux-aarch64-a3-800t-, 与性能 job 使用同一批 800t 节点。

关键文件:

- python/sglang/test/ascend/e2e/test_npu_performance_utils.py (模块 性能看门狗; 类别 test; 类型 test-coverage; 符号 _kill_on_timeout, run_bench_serving, BENCHMARK_STDOUT_IDLE_TIMEOUT, BENCHMARK_STDOUT_DRAIN_GRACE) : 核心变更: run_bench_serving 引入进程组级 watchdog, 新增三个超时常量并覆盖三种僵死场景, 是本 PR 最具技术含量的文件。
- python/sglang/test/ascend/e2e/test_npu_multi_node_utils.py (模块 进程回收; 类别 test; 类型 test-coverage; 符号 kill_process_group) : 新增 kill_process_group 公共工具, 是 perf 与 accuracy 两侧收割进程组的统一入口。
- python/sglang/test/ascend/e2e/test_npu_accuracy_utils.py (模块 精度测试; 类别 test; 类型 test-coverage; 符号 _kill_evalscope_session, kill_process_group, run_evalscope) : 删除本地重复的 _kill_evalscope_session, 统一复用 kill_process_group, 消除两套收割逻辑漂移。
- test/registered/npu/accuracy/qwen3_vl_8b_thinking/test_npu_qwen3_vl_8b_thinking_1p_mmmu.py (模块 MMMU 精度测试; 类别 test; 类型 test-coverage; 符号 TestQwen3_VL_8B_Thinking_MMMU, TestQwen3) : Qwen3-VL 8B thinking 的 MMMU 注册测试: est_time 提升至 12000、环境变量更名 DEEPEP_HCCL_BUFFSIZE、测试类名改为带模型语义。
- test/registered/npu/accuracy/qwen3_vl_30b_a3b_thinking/test_npu_qwen3_vl_30b_a3b_thinking_1p_mmmu.py (模块 MMMU 精度测试; 类别 test; 类型 test-coverage; 符号 TestQwen3_VL_30B_A3B_Thinking_MMMU, TestQwen3) : Qwen3-VL 30B A3B thinking 的 MMMU 注册测试: 环境变量更名与测试类名修正, 与 8B 侧保持一致。
- .github/workflows/pr-test-npu.yml (模块 CI 配置; 类别 infra; 类型 infrastructure) : accuracy 套件四个 stage 的 runner 标签切换为 a3-800t, 与性能 job 对齐节点型号, 是 CI 配置层面的配套变更。
- test/registered/npu/performance/kimi_k2_6/test_npu_kimi_k2_6_w4a8_8p_in3k5_out1k5_20ms.py (模块 性能基准; 类别 test; 类型 test-coverage) : Kimi K2.6 性能测试补充 --max-total-tokens 32256, 限制总 token 数避免长尾任务挂起。

关键符号: kill_process_group, _kill_on_timeout, run_bench_serving, run_evalscope, _kill_evalscope_session

关键源码片段

python/sglang/test/ascend/e2e/test_npu_performance_utils.py

核心变更：run_bench_serving 引入进程组级 watchdog，新增三个超时常量并覆盖三种僵死场景，是本 PR 最具技术含量的文件。

```
# 用独立 session 启动 benchmark，保证 process.pid == pgid，
# 后续无论谁持有 stdout，都能按进程组整体收割。
process = subprocess.Popen(
    cmd_args,
    stdout=subprocess.PIPE,
    stderr=subprocess.STDOUT,
    text=True,
    bufsize=1,
    env=env,
    start_new_session=True,
)

# reader_done 表示 stdout 已读到 EOF；last_activity 记录最后一条输出时间。
reader_done = threading.Event()
last_activity = time.time()

def _kill_on_timeout():
    while True:
        # 场景 1：直接子进程已退出，但 stdout 仍被子孙进程持有。
        # 等待 DRAIN_GRACE 秒让 reader 排空剩余输出，超时则强杀全部。
        if process.poll() is not None:
            if not reader_done.wait(timeout=BENCHMARK_STDOUT_DRAIN_GRACE):
                logger.error(
                    f"Benchmark stdout still open after process exit, "
                    f"killing process group {process.pid}"
                )
                kill_process_group(process)
                return
        # 场景 2：stdout 已 EOF，但直接子进程迟迟不退出。
        if reader_done.is_set():
            try:
                process.wait(timeout=BENCHMARK_STDOUT_DRAIN_GRACE)
            except subprocess.TimeoutExpired:
                logger.error(
                    f"Benchmark {process.pid} still alive after stdout EOF, "
                    f"killing process group {process.pid}"
                )
                kill_process_group(process)
                return
        # 场景 3：进程还在运行但长时间无输出，判定为挂起。
        idle = time.time() - last_activity
        if idle > BENCHMARK_STDOUT_IDLE_TIMEOUT:
            logger.error(
```

```

        f"Benchmark produced no output for {idle:.0f}s "
        f"(> {BENCHMARK_STDOUT_IDLE_TIMEOUT}s), "
        f"killing process group {process.pid}"
    )
    kill_process_group(process)
    return
time.sleep(BENCHMARK_WATCHDOG_POLL_INTERVAL)

```

daemon 线程保证主测试线程结束时 watchdog 不阻塞退出。
 watchdog = threading.Thread(target=_kill_on_timeout, daemon=True)
 watchdog.start()

```

try:
    # 读线程逐行消费 stdout 并刷新 last_activity, 供 watchdog 判断空转。
    with open(result_file, "a", encoding="utf-8") as f:
        for line in process.stdout:
            last_activity = time.time()
            if line.strip():
                print(line, end="")
                f.write(line)
            # ... 解析指标行 ...
finally:
    reader_done.set()
    process.wait()

```

python/sclang/test/ascend/e2e/test_npu_multi_node_utils.py

新增 kill_process_group 公共工具, 是 perf 与 accuracy 两侧收割进程组的统一入口。

```

def kill_process_group(process):
    """SIGKILL 收割整个进程组。

    process 是用 start_new_session=True 启动的 Popen, 其 pid 即进程组 id;
    调用方必须保证这一点, 否则 killpg 会误杀无关进程。
    """
    if process is None:
        return
    try:
        os.killpg(process.pid, signal.SIGKILL)
        logger.info(f"killed process group pgid={process.pid}")
    except ProcessLookupError:
        # 进程组已自然退出, 属于正常情况。
        logger.info(f"process group pgid={process.pid} already gone")
    except PermissionError:
        # 无权限时只告警, 避免掩盖真实问题。
        logger.warning(f"no permission to kill process group pgid={process.pid}")
    except OSError as e:
        # 兜底捕获, 保证清理路径不会二次抛出异常。
        logger.warning(f"failed to kill process group pgid={process.pid}: {e}")

```

评论区精华

cherryblo 的 review 集中在 test_npu_performance_utils.py 的代码可读性：两处要求 add comment（新增的 watchdog 常量与 L504 附近逻辑）、建议把 poll() 分支与 reader_done 分支合并为单个 if 语句、质疑 last_activity 为何用 list 包装、并指出某个条件判断不再需要。作者在后续提交（763a7e1c）中做了实质性简化：移除绝对超时上限

BENCHMARK_SERVING_TIMEOUT、删除 _collect_process_tree / _kill_recorded_pids 的孤儿进程快照记录、把 last_activity 从 list 改为标量，与评论方向一致；但 poll 分支与 reader_done 分支是否最终合并没有明确记录。整体是风格与可读性层面的交锋，没有出现正确性或设计原则的分歧。

- watchdog 新增逻辑需要注释说明 (style): 作者保留并补充注释；后续提交直接移除了绝对超时上限 BENCHMARK_SERVING_TIMEOUT，进一步减少需要解释的配置。
- stdout 处理分支应合并为单个 if 语句 (design): 看门狗在提交 2 中被简化（去掉绝对超时上限、last_activity 改标量），但 poll 分支与 reader_done 分支是否最终合并没有明确记录。
- last_activity 为何用 list 包装 (question): 提交 2 将 last_activity 改为标量，移除了 list 包装，简化共享方式。
- 移除不再需要的超时判断条件 (design): 提交 2 移除了 BENCHMARK_SERVING_TIMEOUT 绝对上限，以 idle 超时 + 排空宽限替代，与建议一致。

风险与影响

- 风险：
 1. 误杀风险 (test_npu_performance_utils.py) : watchdog 在 300 秒无输出即 SIGKILL 整个进程组。benchmark 在长 prefill、模型权重下载或大数据集准备阶段可能长时间无 stdout，存在误杀正常任务的可能；SIGKILL 不留恢复窗口，排障时只能靠日志。
 2. 进程组收割的边界风险 (test_npu_multi_node_utils.py) : kill_process_group 依赖 start_new_session 保证 pid == pgid，若未来有人复用该函数但未用 start_new_session 启动进程，os.killpg 会因进程组不存在或误杀同组进程而静默失败 / 误伤。
 3. DEEPEP_HCCL_BUFFSIZE 改名兼容性：旧变量 HCCL_BUFFSIZE 在底层 deep-ep 版本上是否仍被读取未在 PR 中验证，若新变量名不被 CANN 版本识别，通信 buffer 会回退默认值，可能影响多卡大模型 benchmark 与精度表现。
 4. CI runner 标签切换 (pr-test-npu.yml) : linux-aarch64-a3-800t-* 依赖 runner 池容量与标签准确性，若资源不足或标签未注册，accuracy job 会一直排队阻塞合并。
 5. 影响范围受限：全部为测试与 CI 配置变更，不触碰 srt 运行时代码，无推理路径回归风险。
 - 影响：影响范围限于 Ascend NPU 的 CI 与注册测试体系：benchmark/accuracy 测试不再因进程挂起或孤儿进程拖死 runner，nightly accuracy 与性能回归的稳定性提升；Qwen3-VL thinking 两个 MMMU 测试的命名与配置更贴近模型语义，便于 CI 结果归因。对使用 NPU CI 的维护者和模型验证工程师有直接收益，对运行时用户无感知。影响程度中等偏低。
 - 风险标记：SIGKILL 误杀进程组风险，300 秒无输出判定挂起可能误杀长任务，DEEPEP_HCCL_BUFFSIZE 改名兼容性待验证，CI

runner 标签依赖 a3-800t 资源池，纯测试变更，无运行时影响

关联脉络

- PR #33634 [NPU] Add test for --dllm-fdfo: 同为 NPU 端注册测试，位于同一 test/registered/npu 体系，后续 NPU 测试可复用本 PR 新增的 kill_process_group 看门狗工具。
- PR #36240 [CI] Stop the config ratchets re-parsing the package on every scan: 同属 CI 测试基础设施维护方向，与本 PR 的 NPU CI 稳定性修复互为补充，共同提升 CI 自动化可靠性。