

PR #24445 完整报告

sgl-project/sglang

[fix] /pause_generation and /continue_generation wrong for --tokenizer-worker-num > 1

合并时间: 2026-05-06 07:27

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/24445>

执行摘要

- 一句话: 修复多 tokenizer worker 下暂停 / 继续生成不一致的 bug
- 推荐动作: 推荐精读 `MultiTokenizerRouter.router_worker_obj` 的广播实现和 `MultiHttpWorkerTokenizerMixin` 的广播处理逻辑, 可作为多进程间状态广播的参考设计。建议关注 follow-up: 通过 `op_id` 映射修复并发竞态条件。

功能与动机

Issue #21235 报告: 多 tokenizer worker 模式下, 暂停 / 继续生成只作用于处理请求的那个 worker, 概率性导致部分 worker 永久处于暂停状态, 后续路由到该 worker 的请求无限等待。共享调度器的 `_engine_paused` 标志正确切换, 但 per-worker 的请求门控 (`is_pause_cond`) 被破坏。

实现拆解

1. 新增数据类: 在 `io_struct.py` 中添加 `TokenizerWorkerRegisterReq` (worker 启动时向路由器注册 IPC 名称) 和 `PauseContinueBroadcast` (路由器广播暂停 / 继续状态)。
2. 路由器改造: 在 `MultiTokenizerRouter` 中维护 `all_worker_ipcs` 集合 (记录所有注册过的 worker IPC), `router_worker_obj` 协程在处理 `PauseGenerationReqInput/ContinueGenerationReqInput` 时, 遍历集合通过 `socket_mapping.send_output` 广播 `PauseContinueBroadcast`; 同时保留向 scheduler rank 0 的转发 (abort 模式除外)。
3. Worker 端处理: `MultiHttpWorkerTokenizerMixin` 在初始化时发送 `TokenizerWorkerRegisterReq` 注册自身 IPC, 并新增 `_pause_continue_future` 和 `_handle_pause_continue_broadcast/_apply_pause_continue_broadcast` 方法处理广播: 接收到广播后更新 `is_pause` 标志并通知 `is_pause_cond`, 同时通过 Future 同步等待本地标志翻转后再返回 HTTP 响应。
4. 测试与配套: PR 描述中列出了手动回归测试和现有单元测试的通过计划, 但本次提交未包含新增的自动化测试文件; `handle_loop` 的响应路由路径也共享了 `socket_mapping`, 避免重复创建。

关键文件:

- `python/sglang/srt/managers/multi_tokenizer_mixin.py` (模块 请求路由; 类别 source; 类型 core-logic; 符号 `pause_generation`, `continue_generation`, `_handle_pause_continue_broadcast`, `_apply_pause_continue_broadcast`): 核心逻辑变

更：实现了暂停 / 继续信号从路由器到所有 tokenizer worker 的广播机制，包括 worker 注册、广播发送和响应处理。

- python/sglang/srt/managers/io_struct.py (模块 数据结构; 类别 source; 类型 core-logic; 符号 TokenizerWorkerRegisterReq, PauseContinueBroadcast) : 新增 TokenizerWorkerRegisterReq 和 PauseContinueBroadcast 两个 dataclass, 定义了 worker 注册和广播的数据契约。

关键符号: pause_generation, continue_generation, _handle_pause_continue_broadcast, _apply_pause_continue_broadcast

关键源码片段

python/sglang/srt/managers/multi_tokenizer_mixin.py

核心逻辑变更：实现了暂停 / 继续信号从路由器到所有 tokenizer worker 的广播机制，包括 worker 注册、广播发送和响应处理。

```
async def router_worker_obj(self):
    """Forward path: workers → scheduler, with pause/continue broadcast."""
    while True:
        recv_obj = await self.receive_from_worker.recv_pyobj()

        if isinstance(recv_obj, TokenizerWorkerRegisterReq):
            # 每个 TokenizerWorker 启动时注册自己的 IPC 名称, 避免重复添加
            if recv_obj.worker_ipc_name not in self.all_worker_ipcs:
                self.all_worker_ipcs.add(recv_obj.worker_ipc_name)
                logger.info(
                    f"Router registered worker IPC: {recv_obj.worker_ipc_name} "
                    f"(total: {len(self.all_worker_ipcs)})"
                )
            continue

        if isinstance(
            recv_obj, (PauseGenerationReqInput, ContinueGenerationReqInput)
        ):
            # 广播暂停 / 继续信号到所有已注册 worker
            is_pause = isinstance(recv_obj, PauseGenerationReqInput)
            broadcast = PauseContinueBroadcast(is_pause=is_pause)
            for ipc_name in self.all_worker_ipcs:
                self.socket_mapping.send_output(ipc_name, broadcast)

            # abort 模式通过轮询释放, 不需要转发到 scheduler
            if not (
                isinstance(recv_obj, PauseGenerationReqInput)
                and recv_obj.mode == "abort"
            ):
                # 只需转发到 scheduler rank 0, 内部会广播到所有 TP/PP/DP ranks
                await self.send_to_scheduler.send_pyobj(recv_obj)
            continue
```

```
# 普通请求直接转发给 scheduler
await self.send_to_scheduler.send_pyobj(recv_obj)
```

评论区精华

Review 中重点关注了三个技术点：(1) `socket_mapping.send_output` 是同步阻塞调用，在 `async` 循环中使用可能导致性能问题或全局挂起；(2) 建议用 `set` 替代 `list` 存储 worker IPC 名称，避免 worker 重启时重复注册；(3) 单个 `_pause_continue_future` 在并发暂停 / 继续请求到同一 worker 时会因覆盖导致前一个请求挂起。前两个建议已被作者采纳，第三个作为 follow-up 记录。

- 同步 ZMQ 调用在 `async` 循环中的性能风险 (performance): 未在评论中明确解决，但性能影响被作者认为可接受（延迟 sub-ms），PR 合并时未引发进一步争论
- 使用 `set` 而非 `list` 存储 worker IPC 名称 (design): 作者在第三次提交中接受建议，将 `all_worker_ipcs` 从 `list` 改为 `set`，并调整注册逻辑去重
- 单个 `future` 在并发暂停 / 继续请求下的竞态条件 (design): PR 作者在 `body` 的 Notes/follow-ups 中承认此问题，认为顺序使用（bug 重现场景）没问题，并建议后续使用 `op_id` 键化的 `future map` 加固

风险与影响

- 风险：
 - 同步 ZMQ 调用：`socket_mapping.send_output` 在 `router_worker_obj` 和 `handle_loop` 的 `async` 循环中阻塞，若 worker 处理慢或 ZMQ 缓冲满，可能导致整体延迟增长甚至事件循环挂起。当前场景下广播仅涉及同主机 IPC，延迟 sub-ms，风险可控。
 - 并发竞态条件：同一 worker 进程上连续收到多个暂停 / 继续请求时，`_pause_continue_future` 可能被覆盖，导致前端请求挂起。PR 明确指出后续需用 `op_id` 键化的 `future map` 修复。
 - worker 注册时序依赖：依赖所有 worker 在 HTTP 流量开始前完成注册，当前启动顺序满足条件，但若未来动态增减 worker，可能注册不完全。
 - 缺少测试覆盖：PR 在 `body` 中列出了测试计划，但本次提交未包含自动化回归测试，后续若重构可能引入回归。
- 影响：
 - 用户影响：修复了多 tokenizer worker 部署下暂停 / 继续生成命令不可用的问题，提升 PD 分离场景的可靠性。所有使用 `--tokenizer-worker-num > 1` 的用户均受益。
 - 系统影响：新增的广播过程引入了一次额外的 IPC 往返（worker → router → worker），同主机环境下延迟可忽略。无 ABI/API 破坏。
 - 团队影响：为后续类似广播模式提供了可复用的 `all_worker_ipcs` 注册和 `PauseContinueBroadcast` 机制，降低未来扩展成本。
 - 风险标记：核心路径变更，同步阻塞调用，并发竞态条件，缺少测试覆盖

关联脉络

- 暂无明显关联 PR