

PR #29017 完整报告

sgl-project/sglang

[model-gateway] PD router: cancel paired decode when prefill fails

合并时间: 2026-07-03 08:03

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29017>

PR #29017 分析报告: PD 路由 prefill 失败时取消 decode 请求

执行摘要

本 PR 将 PD 分离部署中路由器的 prefill 和 decode 请求并发控制从 `tokio::join!` 改为 `tokio::select!`, 实现了 prefill 请求失败时立即丢弃 decode 请求并关闭连接, 使 decode 插槽释放时间从 300s 缩短至约 4-8s。这是引擎侧修复 #28651 在路由层的补充, 覆盖了 prefill HTTP 失败场景, 显著降低级联死锁风险。

功能与动机

在 PD 分离部署模式下, decode 节点必须等待 prefill 节点传输 KV cache 后才能开始生成。若 prefill 请求因超时、5xx、连接拒绝等原因失败, decode 请求将在 `KVPoll.WaitingForInput` 状态阻塞长达 300s (默认 `SGLANG_DISAGGREGATION_WAITING_TIMEOUT`), 期间占用解码槽位, 导致并发度下降。当多个 prefill 失败时, 形成级联死锁, 集群恢复时间可达 1 小时以上。

关联 Issue #28651 描述了类似的生产事故: "The 300s decode hang per aborted request was the key amplifier that turned a transient prefill disruption into a prolonged cluster-wide outage."

实现拆解

1. 并发模型改造 (`pd_router.rs:execute_dual_dispatch_internal`) - 将原来的 `tokio::join!(prefill_fut, decode_fut)` 替换为 `tokio::select!` 循环, 优先等待 prefill 完成 (`biased` 模式)。- decode 如果先完成, 暂存其结果但不中断循环, 继续等待 prefill。- 两个 future 仍然在同一个 handler 任务中运行 (未使用 `tokio::spawn`), 保留客户端断开时自动取消的行为。
2. 快速失败路径 - prefill 返回非 2xx 或传输错误时, 记录警告日志, 并调用 `process_prefill_response` 生成 HTTPS 响应: 4xx 透传、5xx/ 传输错误转换为 502。- 通过释放作用域隐式 drop decode future, 关闭其 HTTP 连接。decode 引擎在 4-8s 内检测到连接断开并调用 `abort_request()`, 释放解码槽位。
3. 断路器归属处理 - 仅根据 prefill 实际状态记录断路器结果: 4xx 记为客户端错误 (不影响断路器熔断), 其余不记录。- decode 端不记录 (避免 prefill 故障风暴误伤正常 decode)

断路器)。 - 响应中插入 `BreakerOutcomesRecorded` 标记, 通知外层调度器跳过重复记录。

4. 正常路径完全不变 - `prefill` 成功后, 从 `decode_early` 或再次 `await decode future` 获取结果, 后续处理 (状态检查、流式处理、断路器跟踪等) 与原来一致。

sgl-model-gateway/src/routers/http/pd_router.rs

核心变更文件, PD 路由的并发控制从 `tokio::join!` 重构为 `tokio::select!`, 实现 `prefill` 失败时快速关闭 `decode` 连接。

```
// sgl-model-gateway/src/routers/http/pd_router.rs

// 将 prefill 和 decode 的 future 固定, 确保它们在同一个任务中运行
let prefill_fut = prefill_request.send();
let decode_fut = decode_request.send();
tokio::pin!(prefill_fut);
tokio::pin!(decode_fut);

let prefill_result;
let mut decode_early: Option<Result<request::Response, request::Error>> = None;
loop {
    tokio::select! {
        biased; // 优先 poll prefill, 避免 decode 先完成时误判
        pr = &mut prefill_fut => {
            prefill_result = pr;
            break;
        }
        dr = &mut decode_fut, if decode_early.is_none() => {
            // decode 先完成则暂存结果, 但不中断等待 prefill
            decode_early = Some(dr);
        }
    }
}

// 判断 prefill 是否失败 (非 2xx 或传输错误)
let prefill_failed = match &prefill_result {
    Ok(resp) => !resp.status().is_success(),
    Err(_) => true,
};

if prefill_failed {
    warn!(
        "Prefill failed, aborting paired decode request decode_url={} prefill_url={}",
        decode.url(),
        prefill.url()
    );

    // 仅记录 prefill 断路器结果, decode 不记录避免误伤
    let prefill_ok = match &prefill_result {
```

```

        Ok(r) => r.status().is_client_error(),
        Err(_) => false,
    };
    prefill.record_outcome(prefill_ok);

    // 生成错误响应 (4xx 透传, 5xx/ 传输错误 -> 502)
    let mut response = match self
        .process_prefill_response(prefill_result, prefill.url(), false)
        .await
    {
        Err(error_response) => error_response,
        Ok(_) => error::bad_gateway(
            "prefill_server_error",
            "Prefill reported failure but returned a success response".to_string(),
        ),
    };
    response.extensions_mut().insert(BreakerOutcomesRecorded);
    return response;
}

// Prefill 成功: 获取 decode 结果 (若尚未完成则等待)
let decode_result = match decode_early {
    Some(dr) => dr,
    None => (&mut decode_fut).await,
};

// 后续处理与之前一致 (状态检查、流式处理等)

```

评论区精华

Gemini Code Assist: " 优化建议: decode future 先于 preflight 完成时, 可以立即 fail-fast 并返回, 因为 PD 模式下 decode 不可能成功。"

chenkaiyue: " 保留当前实现, 原因: ① 极罕见情况下 decode 可能返回 2xx (时序竞态); ② 早期返回会重复下游已有的 decode 错误处理逻辑; ③ 性能收益微乎其微。"

此讨论体现了对边缘情况的严谨考虑: 虽然理论上 decode 不能先成功, 但实践中可能存在非常短的生成序列, 时序竞态可能导致 decode 意外返回 2xx, 直接 fail-fast 反而会误报。

风险与影响

- 回归风险: tokio::select! 的 biased 模式和行为与 join! 不同, 若理解偏差可能导致任务泄漏或死锁。但代码通过 tokio::pin! 确保生命周期, 且已通过生产环境验证。
- 兼容性风险: decode 端不再记录断路器结果, 若其他组件依赖此计数可能需要同步更新。
- 测试覆盖不足: 本次变更仅修改源码, 未添加测试, 建议 merge 前补充单元测试覆盖 prefill 失败、decode 先完成、客户端断开等场景。

关联脉络

- #28651 (引擎侧修复) : 在 mooncake 层面实现 prefill 中止时通知 decode 对端。本 PR 是路由层补充, 覆盖 prefill HTTP 失败场景 (如 4xx/5xx、连接拒绝)。两者结合后, PD 模式下 prefill 故障不再导致 decode 长时间阻塞。
- 近期历史: 多 PR 围绕 PD 分离部署的稳定性改进 (如 #29756 MiniMax M3 状态传输修复、#29982 AMD FlashMLA 稀疏 prefill 关闭), 反映了该仓库对生产环境健壮性的持续投入。