

PR #1873 完整报告

THUDM/slime

[Fix] Use Ray ObjectRef await instead of asyncio.to_thread in distributed POST

合并时间: 2026-04-28 10:35

原文链接: <http://prhub.com.cn/THUDM/slime/pull/1873>

执行摘要

- 一句话: 移除分布式 POST 的线程池瓶颈, 直接 await Ray ObjectRef
- 推荐动作: 该 PR 虽改动极小, 但值得所有使用分布式 POST 的团队关注。建议精读以理解 asyncio 与 Ray 集成的正确用法, 并可作为后续异步化其他阻塞调用的参考。

功能与动机

分布式 POST 路径使用 `asyncio.to_thread(ray.get, obj_ref)`, 其底层线程池隐含 `min(32, cpu+4)` 的并发上限, 高并发下导致大量请求排队等待 OS 线程, 产生人为尾延迟和响应突发。Ray 的 `ObjectRef` 本身就支持 asyncio await, 可直接等待而不占用线程。

实现拆解

1. 定位瓶颈: 在 `slime/utils/http_utils.py` 的 `post()` 函数中, 分布式分支通过 `asyncio.to_thread(ray.get, obj_ref)` 将 `ray.get` 提交到事件循环的默认线程池, 受限于 `ThreadPoolExecutor` 的固定线程数。
2. 直接替换: 将 `return await asyncio.to_thread(ray.get, obj_ref)` 改为 `return await obj_ref`, 利用 Ray 的 asyncio 集成——`ObjectRef` 可作为 `asyncio.Future` 等待, 由 Ray 内部通过 `loop.call_soon_threadsafe` 唤醒协程, 不消耗 OS 线程。
3. 保持其他逻辑不变: 异常处理、回退本地路径、非分布式路径均未改动。

关键文件:

- `slime/utils/http_utils.py` (模块 网络工具; 类别 source; 类型 core-logic): 本次变更的唯一文件, 修改了分布式 POST 路径的核心等待逻辑。

关键符号: `post`

关键源码片段

`slime/utils/http_utils.py`

本次变更的唯一文件, 修改了分布式 POST 路径的核心等待逻辑。

```
# slime/utils/http_utils.py (post 函数分布式分支)
```

```
async def post(url, payload, max_retries=60, headers=None):  
    # If distributed mode is enabled and actors exist, dispatch via Ray.
```

```

if _distributed_post_enabled and _post_actors:
    try:
        import ray

        actor = _next_actor()
        if actor is not None:
            # Await the Ray ObjectRef directly. The previous
            # `asyncio.to_thread(ray.get, obj_ref)` blocked an OS thread
            # from the default ThreadPoolExecutor (capped at
            # `min(32, cpu+4)`), which becomes a hard upper bound on the
            # number of in-flight POSTs that can be waited on in parallel
            # and produces large tail latencies under high concurrency.
            obj_ref = actor.do_post.remote(url, payload, max_retries, headers=headers)
            return await obj_ref # 不再占用线程池，直接等待 Ray 的异步回调
        except Exception as e:
            logger.info(f"[http_utils] Distributed POST failed, falling back to local: {e} (url={url})")
            # fall through to local

    return await _post(_http_client, url, payload, max_retries, headers=headers)

```

评论区精华

该 PR 没有任何 review 评论或讨论。

- 暂无高价值评论线程

风险与影响

- 风险：低风险。变更仅替换了一行核心调用，且利用了 Ray 官方文档推荐的 `asyncio` API。主要风险在于：若使用者不需要 `asyncio` 环境（如纯同步上下文），则 `await` 可能不适用；但当前函数已被声明为 `async`，因此变更安全。此外，回退机制保留，异常时仍可降级到本地 POST。
- 影响：影响范围局限于启用 `--use-distributed-post` 的部署场景。预期收益：在高并发 POST 请求下，消除线程池瓶颈，降低尾延迟，提高吞吐量。非分布式路径及其他功能无影响。
- 风险标记：低风险，核心路径变更但改动极小

关联脉络

- 暂无明显关联 PR