

PR #2238 完整报告

THUDM/slime

fix: stop the fully-async rollout dropping completed groups

合并时间: 2026-08-12 14:05

原文链接: <http://prhub.com.cn/THUDM/slime/pull/2238>

执行摘要

- 一句话: 修复全异步 rollout 丢弃已完成组并解除事件循环阻塞
- 推荐动作: 值得精读。该 PR 是典型的“两个缺陷相互耦合、需联动修复”的案例, 其背压转移设计(将有界队列改为无界、在生产者侧用 `qsize` 门控)是一个可复用的异步队列模式。建议关注 `get_completed_groups` 的 `limit` 语义与 `_loop` 门控条件, 理解为何“无界队列 + 显式门控”优于“有界队列 + 阻塞 put”在事件循环线程中的表现。

功能与动机

PR body 明确指出两个缺陷:

1) `_generate_rollout_async` 每次轮询排空整个输出队列, 却只返回 `[:rollout_batch_size]` 的切片, 超出的 group 被丢弃——这些 group 已完成生成和奖励打分, 且 prompt 已从 `data_buffer` 消费, 永远丢失, 属于 GPU 算力浪费; 2) 任务完成回调运行在事件循环线程上, 向 `maxsize=1000` 的有界队列做阻塞 put, 当在途 group 数(示例配置 $512 \times 3 = 1536$)超过上限时, 回调会阻塞事件循环, 冻结所有在途生成。两个缺陷相互耦合: 单独修 bug 1 会让盈余积压成为常态, 使 bug 2 从偶发卡顿变成必然冻结。

实现拆解

1. 修改队列拉取契约: `slime/rollout/fully_async_rollout.py` 中 `get_completed_groups` 新增 `limit: int | None = None` 参数, 按需弹出最多 `limit` 个 group (None 时全部弹出)。
`_generate_rollout_async` 的 poll 循环改为每次只取 `target - len(collected)` 个, 盈余继续留在队列中等待下一次 rollout, 恢复文档承诺的 "queue stays warm" 行为, 同时删除原来 `[:target]` 的丢弃切片。
2. 移除事件循环阻塞源: `AsyncRolloutWorker.__init__` 中将 `queue.Queue(maxsize=1000)` 改为无界 `queue.Queue()`, 避免 `done-callback` 在事件循环线程上阻塞。真正的背压转移到 `_loop()` 的 top-up 门控: 仅当 `output_queue.qsize() < max_concurrent` 时才继续从 `data_buffer` 拉取新 prompt, 内存上界约为 $2 \times \text{concurrency}$ 个 group, 与原先在途池数量级一致。
3. 可配置轮询间隔: `_loop` 中两处 `sleep(1)` 改为 `sleep(self.poll_interval)` (默认 1.0, 行为不变), 使 CPU 测试可以调小间隔快速驱动循环。
4. 新增 CPU 单测与 CI 注册: 新增 `tests/test_fully_async_rollout.py`, 通过 `stub` `sglang_router/transformers` 在无 GPU 环境验证四条核心行为: 生成返回恰好 `target` 个

FIFO group 且盈余留队、get_completed_groups 的 limit 语义、done-callback 超过旧 1000 容量上限不阻塞、以及背压门控让队列维持 $\leq 2 \times \text{concurrency}$ 。在 .github/workflows/pr-test.yml 和 .github/workflows/pr-test.yml.j2 的 cpu-unitest 作业中注册新测试。

关键文件：

- slime/rollout/fully_async_rollout.py (模块 异步队列；类别 source；类型 core-logic；符号 AsyncRolloutWorker.init, AsyncRolloutWorker.get_completed_groups, AsyncRolloutWorker._loop, _generate_rollout_async)：核心修复文件，涉及队列契约、背压机制和轮询间隔三处关键改动。get_completed_groups 新增 limit 参数，output_queue 改为无界，_loop 增加 qsize 门控。
- tests/test_fully_async_rollout.py (模块 异步队列；类别 test；类型 test-coverage；符号 _FakeGenerateState, _FakeDataBuffer, _make_group, _make_worker)：新增 CPU 单测，覆盖队列契约、limit 语义、done-callback 不阻塞和背压门控四条核心行为，是验证本次修复的关键配套。
- .github/workflows/pr-test.yml (模块 CI 配置；类别 infra；类型 infrastructure)：在 cpu-unitest 作业中注册新测试文件，确保 CI 覆盖。
- .github/workflows/pr-test.yml.j2 (模块 CI 配置；类别 infra；类型 infrastructure)：pr-test.yml 的模板源文件，同步新增测试条目。

关键符号：AsyncRolloutWorker.init, AsyncRolloutWorker.get_completed_groups, AsyncRolloutWorker._loop, _generate_rollout_async

关键源码片段

slime/rollout/fully_async_rollout.py

核心修复文件，涉及队列契约、背压机制和轮询间隔三处关键改动。get_completed_groups 新增 limit 参数，output_queue 改为无界，_loop 增加 qsize 门控。

```
# slime/rollout/fully_async_rollout.py
class AsyncRolloutWorker:
    def __init__(self, args, data_buffer, concurrency: int = 10):
        self.args = args
        self.data_buffer = data_buffer
        self.concurrency = concurrency
        self.running = True
        # 输出队列改为无界：put() 运行在事件循环线程 (task done-callback)，
        # 有界队列一旦写满会阻塞循环本身，冻结所有在途生成。
        # 真正的背压转移到 _loop() 的 top-up 门控。
        self.output_queue: queue.Queue[tuple[int, list[Sample]]] = queue.Queue()
        self.poll_interval = 1.0
        self.worker_thread: threading.Thread | None = None
        self.state = GenerateState(args)

    def get_completed_groups(self, limit: int | None = None) -> list[tuple[int, list[Sample]]]:
        """最多弹出 ``limit`` 个已完成 group (``None`` 时全部弹出)。
```

只需固定数量 group 的调用方必须传 ``limit``——超出部分一旦弹出就会被丢弃，而这些 group 已完成生成与奖励打分，且其 prompt 已从 ``data\_buffer`` 消费掉，无法重新入队。

"""

```
completed: list[tuple[int, list[Sample]]] = []
while limit is None or len(completed) < limit:
    try:
        completed.append(self.output_queue.get_nowait())
    except queue.Empty:
        break
return completed
```

```
async def _loop(self) -> None:
```

```
    active_tasks: set[asyncio.Task] = set()
    max_concurrent = self.concurrency
    gid_counter = 0
```

```
    while self.running:
```

```
        try:
            # 收割已完成的 task
            if active_tasks:
                done = {t for t in active_tasks if t.done()}
                for t in done:
                    try:
                        t.result() # 结果已在回调中处理
                    except Exception as e: # noqa: BLE001
                        logger.warning("fully-async task crashed: %r", e)
                active_tasks -= done
```

```
        # 补给。qsize 门控承担背压：一旦已有一整批（concurrency）已完成
        # group 排队等待消费，就暂停拉取新 prompt，直到训练侧消费掉一些。
        while (
```

```
            len(active_tasks) < max_concurrent
            and self.output_queue.qsize() < max_concurrent
            and self.running
```

```
        ):
```

```
            groups = self.data_buffer.get_samples(1)
            if not groups:
                break
            for group in groups:
                gid = gid_counter
                gid_counter += 1
                task = asyncio.create_task(
                    generate_and_rm_group(
                        self.args,
                        group,
                        sampling_params=self.state.sampling_params.copy(),
                        evaluation=False,
                    )
```

```

    )
    task.add_done_callback(self._make_done_cb(gid))
    active_tasks.add(task)

    await asyncio.sleep(self.poll_interval)
except Exception as e: # noqa: BLE001
    logger.exception("fully-async loop iteration error: %s", e)
    await asyncio.sleep(self.poll_interval)

```

tests/test_fully_async_rollout.py

新增 CPU 单测，覆盖队列契约、limit 语义、done-callback 不阻塞和背压门控四条核心行为，是验证本次修复的关键配套。

```

# tests/test_fully_async_rollout.py
def _make_worker(monkeypatch, data_buffer=None, concurrency=4) -> fa.AsyncRolloutWorker:
    monkeypatch.setattr(fa, "GenerateState", _FakeGenerateState)
    args = SimpleNamespace(rollout_global_dataset=True, rollout_batch_size=4)
    return fa.AsyncRolloutWorker(args, data_buffer or _FakeDataBuffer([]), concurrency=
concurrency)

@pytest.mark.unit
def test_rollout_takes_target_groups_and_leaves_surplus_queued(monkeypatch):
    # 队列预热 10 个已完成 group，目标 batch 为 4。
    worker = _make_worker(monkeypatch)
    for gid in range(10):
        worker.output_queue.put((gid, _make_group(gid)))
    monkeypatch.setattr(fa, "_get_global_worker", lambda args, data_buffer: worker)

    args = SimpleNamespace(rollout_global_dataset=True, rollout_batch_size=4)
    out = asyncio.run(fa._generate_rollout_async(args, rollout_id=0, data_buffer=None))

    assert len(out) == 4
    # FIFO: 最老的 4 个先出队。
    assert [group[0].index for group in out] == [0, 1, 2, 3]
    # 其余 6 个仍留在队列中等待下一次 rollout，而不是被丢弃。
    assert worker.queue_size() == 6
    assert [gid for gid, _ in worker.get_completed_groups()] == [4, 5, 6, 7, 8, 9]

```

评论区精华

该 PR 无逐行 review 评论，但 Issue 评论中有外部反馈：shinytang6 表示团队遇到类似问题并请求 zhuzilin 处理；zhuzilin 回复感谢 bugfix 并道歉延迟 review。这说明该缺陷已影响真实用户，修复得到维护者认可。

- fully-async 问题被外部确认 (other): 外部用户确认遇到相同问题，维护者致谢并合并。

风险与影响

- 风险:

1. 无界队列内存风险: 虽然 `_loop` 的 `qsize` 门控限制了队列长度约为 `concurrency`, 但若训练侧长时间不调用 `generate_rollout` 消费队列, 且 `worker` 持续完成生成, 队列最多仍会涨到约 `concurrency` 的量级, 内存有界, 但依赖门控逻辑正确性。若未来有人修改 `_loop` 条件, 可能破坏此约束。
2. `warm-queue` 语义变化: 原先每次 `generate_rollout` 排空队列的隐式行为被替换为“取走目标数量、留下盈余”, 任何依赖旧行为的调用方 (例如期望每次拿到的 `group` 是“当前所有已完成”的代码) 需要显式传 `limit=None` 才能保持旧行为。当前库内调用已全部适配, 但外部使用者需注意。
3. 测试覆盖局限: CPU 测试 stub 了 `sglang_router` 和 `transformers`, 未覆盖真实 `sglang` 后端下的并发行为; 在途任务异常回调路径 (`_make_done_cb` 的异常分支) 也没有专门测试。
4. `poll_interval` 配置化: 默认值保持 1.0, 无行为回归; 但若用户调小间隔, 可能增加 CPU 空转, 影响甚微。
 - 影响: 该修复直接影响使用 `fully-async rollout` 模式的用户 (尤其是 `examples/fully_async/run-qwen2.5-0.5B-fully_async.sh` 这类高并发配置), 消除了训练数据被静默丢弃和事件循环冻结导致训练停摆的问题, 提升训练吞吐与稳定性。对团队而言, 该 PR 明确了队列契约并附带可回归的 CPU 测试, 降低了后续维护风险。改动集中在 `slime/rollout/fully_async_rollout.py` 一个源文件, 影响面可控。
 - 风险标记: 核心异步路径变更, 无界队列内存风险, `warm-queue` 语义变化, 依赖调用方传 `limit`

关联脉络

- PR #2170 Fix placement group crash for external engines under `debug_rollout_only`: 同为 rollout 基础设施稳定性修复, 涉及 `slime/ray` 与参数校验, 与本 PR 共同保障外部引擎和异步 rollout 路径的可靠性。
- PR #2242 fix: honor every `eval.defaults` key and restore per-dataset stop / `min_new_tokens`: 同属 rollout 模块相关修复, 修改了 `slime/rollout/sglang_rollout.py` 与 `eval` 配置, 与本 PR 同属 rollout 稳定化工作线。