

PR #2244 完整报告

radixark/miles

pass the engine weight version from the trainer instead of polling the router

合并时间: 2026-08-08 05:56

原文链接: <http://prhub.com.cn/radixark/miles/pull/2244>

执行摘要

- 一句话: 权重版本由训练器直传, 去掉 router 轮询
- 推荐动作: 值得精读。核心设计决策是“把权威状态从轮询改为推送”: 引擎版本号本来就是训练器写出的, 读回它只会引入延迟和抖动。值得关注的点: 打版本戳统一上移到 `mixin._finalize_and_resume_engines` 以覆盖 LoRA, 以及 `set_weight_version` 对版本回退的 `assert/` 告警二态处理。建议跟进两个后续: `--indep-dp` 下版本计数器的持久化 / 恢复 (P2), 以及补 LoRA 路径的 staleness 测试。

功能与动机

PR body 指出: `FullyAsyncRolloutFn` 需要当前引擎权重版本衡量并限制 sample 陈旧度, 但旧实现是每次 drain group 后通过 HTTP 轮询 router `/model_info` (带 1s TTL), 而这个数字本来就是训练器自己写进引擎的 (`update_weight_version(weight_version=str(self.weight_version))`), 轮询只是读回刚写下的值。改成直传后: 不再因 router 抖动降级为 `None`, 也不再需要特判引擎更新前的 `"default"` 字符串, 并且为 #2030 把 staleness 控制搬进 `fully-async` 数据缓冲扫清了每次 HTTP 往返的成本。

实现拆解

实现按 5 步拆解:

1. 数据契约扩展: `miles/rollout/base_types.py` 给 `RolloutFnTrainInput` 增加 `weight_version: int | None = None` 字段, 镜像已有的 `RolloutFnEvalInput`。冻结 `dataclass` 新增带默认值字段不会破坏既有按位置传参的调用点。
2. 训练侧推送: `miles/backends/megatron_utils/actor.py` 与 `miles/backends/experimental/fsdp_utils/actor.py` 都在 rank 0 于 `update_weights()` 返回后调用 `self.rollout_manager.set_weight_version.remote(self.weight_updater.weight_version)`, 与既有 `clear_updatable_has_new_engines` 调用同一前置条件 (权重推送已结束)。
3. `RolloutManager` 承接: `miles/ray/rollout/rollout_manager.py` 新增 `weight_version` 属性和 `set_weight_version` 方法; 方法内对版本回退做检查——`--indep-dp` 容错模式下仅 `logger.warning`, 否则直接 `assert` 失败; `_get_rollout_data` 构造 `RolloutFnTrainInput` 时带上 `weight_version=self.weight_version`。

4. 消费侧去轮询: `miles/rollout/fully_async_rollout.py` 删除 `_CachedWeightVersion` 类、`httpx/time` 依赖、`WEIGHT_VERSION_QUERY_TIMEOUT_SECS` 常量; `_drain` 签名从 `rollout_id: int` 改为 `input: RolloutFnTrainInput`, `staleness` 计算直接使用 `input.weight_version`。
5. 引擎打戳统一: 把 `engine.update_weight_version.remote(...)` 从 p2p 传输路径的 `_finalize_and_resume_engines` 重写中上移到 `mixin.py` 的公共 `_finalize_and_resume_engines`, 覆盖 full-param 与 LoRA 两类更新路径 (对应 commit a4cb8d3)。

配套测试: `tests/fast/rollout/test_fully_async_rollout.py` 中 `test_stale_group_recycled` 改为直接 `RolloutFnTrainInput(weight_version=10)`; 删除 `test_weight_version_throttles_failed_queries`, 新增 `test_staleness_filter_off_before_the_first_weight_update` 验证首轮更新前 `None` 语义 (过滤关闭而非 `staleness=0`)。

关键文件:

- `miles/rollout/fully_async_rollout.py` (模块 异步驱动; 类别 source; 类型 dependency-wiring; 符号 `_CachedWeightVersion`, `_drain`): 核心消费路径: 删除 `_CachedWeightVersion` 轮询器, `_drain` 改为从 `RolloutFnTrainInput.weight_version` 读取当前版本, 是本次重构的主战场 (+4/-35)。
- `miles/ray/rollout/rollout_manager.py` (模块 管理器; 类别 source; 类型 core-logic; 符号 `set_weight_version`): 新增 `weight_version` 状态与 `set_weight_version` 推送入口, 并在 `_get_rollout_data` 中把版本注入 `RolloutFnTrainInput`, 是训练器到 rollout 的衔接点, 也承载版本回退检查。
- `miles/backends/megatron_utils/update_weight/update_weight_from_distributed/mixin.py` (模块 权重更新; 类别 source; 类型 core-logic; 符号 `_finalize_and_resume_engines`): 把引擎打版本戳统一到公共 `_finalize_and_resume_engines`, 同时覆盖 full-param 与 LoRA 更新路径, 直接回应 reviewer 的 P1 评论。
- `miles/backends/megatron_utils/update_weight/update_weight_from_distributed/p2p.py` (模块 权重更新; 类别 source; 类型 core-logic; 符号 `_finalize_and_resume_engines`): 删除该路径自己的 `_finalize_and_resume_engines` 重写, 避免与 `mixin` 公共实现重复打戳。
- `miles/rollout/base_types.py` (模块 基类型; 类别 source; 类型 data-contract; 符号 `RolloutFnTrainInput`): `RolloutFnTrainInput` 增加 `weight_version` 字段, 是训练器到 fully-async rollout 的数据契约变更。
- `miles/backends/megatron_utils/actor.py` (模块 Megatron 后端; 类别 source; 类型 core-logic; 符号 `update_weights`): Megatron 训练 actor 在 `update_weights` 后 rank 0 推送版本号到 `RolloutManager`。
- `miles/backends/experimental/fsdp_utils/actor.py` (模块 FSDP 后端; 类别 source; 类型 core-logic; 符号 `update_weights`): FSDP 训练 actor 同步接入推送逻辑, 保持两个后端的 fully-async 行为一致。
- `tests/fast/rollout/test_fully_async_rollout.py` (模块 单元测试; 类别 test; 类型 test-coverage; 符号 `test_stale_group_recycled`, `test_staleness_filter_off_before_the_first_weight_update`): 测试从

FakeWeightVersion 注入改为 input 传参，新增 None 语义覆盖，删除轮询节流测试，是本次行为变化的主要验证。

关键符号：FullyAsyncRolloutFn._drain, RolloutManager.set_weight_version, DistBucketedWeightUpdateMixin._finalize_and_resume_engines, MegatronActor.update_weights, FSDPActor.update_weights

关键源码片段

miles/rollout/fully_async_rollout.py

核心消费路径：删除 `_CachedWeightVersion` 轮询器，`_drain` 改为从 `RolloutFnTrainInput.weight_version` 读取当前版本，是本次重构的主战场（+4/-35）。

```
async def _drain(self, input: RolloutFnTrainInput) -> RolloutFnTrainOutput:
    args = self.args
    assert args.rollout_global_dataset

    target_data_size = args.rollout_batch_size
    data: list[Group] = []
    aborted_groups_recycled = 0
    stale_groups_recycled = 0
    staleness_values: list[int] = []
    metric_gatherer = MetricGatherer()
    do_print = True

    while len(data) < target_data_size:
        prompt_group, group = await self._next_group()
        assert len(group) == args.n_samples_per_prompt

        # 权重更新打断了生成：整组退回数据源重新采样
        if any(s.status == Sample.Status.ABORTED for s in _iter_samples(group)):
            self._recycle(prompt_group)
            aborted_groups_recycled += 1
            continue

        if args.max_weight_staleness is not None:
            oldest = group_oldest_weight_version(group)
            # 引擎权重版本现在由训练器经 RolloutFnTrainInput 直传，
            # 不再每消费一个 group 就轮询 router 的 /model_info
            current = input.weight_version
            if oldest is not None and current is not None:
                staleness = current - oldest
                staleness_values.append(staleness)
                if staleness > args.max_weight_staleness:
                    self._recycle(prompt_group)
                    stale_groups_recycled += 1
                    logger.info(
                        f"Recycled stale group (oldest_version={oldest}, current={current}, "
                        f"staleness={staleness} > max={args.max_weight_staleness})"
```

```

        )
        continue

# 动态过滤：被丢弃的组不进训练也不回收
filter_output = call_dynamic_filter(self._dynamic_filter, args, group)
if not filter_output.keep:
    metric_gatherer.on_dynamic_filter_drop(reason=filter_output.reason)
    continue

data.append(group)
# 后续：首样本日志、指标汇总与 RolloutFnTrainOutput 组装

```

miles/ray/rollout/rollout_manager.py

新增 `weight_version` 状态与 `set_weight_version` 推送入口，并在 `_get_rollout_data` 中把版本注入 `RolloutFnTrainInput`，是训练器到 rollout 的衔接点，也承载版本回退检查。

```

@ray.remote
class RolloutManager:
    def __init__(self, args, pg):
        self.pg = pg
        self.args = args
        # 由训练 actor 在每次权重更新后写入；None 表示尚未发生权重更新
        self.weight_version: int | None = None

    def set_weight_version(self, weight_version: int):
        # 版本回退说明另一个 cell 接管了更新 (--indep-dp 容错场景)，
        # 此时只告警；否则直接断言失败以暴露计数器不一致
        if self.weight_version is not None and weight_version < self.weight_version:
            message = f"Engine weight version went backwards: {self.weight_version} -> {weight_version}"
            assert self.args.indep_dp, message
            logger.warning(message)
        self.weight_version = weight_version

```

miles/backends/megatron_utils/update_weight/update_weight_from_distributed/mixin.py

把引擎打版本戳统一到公共 `_finalize_and_resume_engines`，同时覆盖 full-param 与 LoRA 更新路径，直接回应 reviewer 的 P1 评论。

```

def _finalize_and_resume_engines(self) -> None:
    """关闭权重更新会话并恢复 rollout 引擎。"""
    if dist.get_rank() == 0:
        # 统一在此处打版本戳：覆盖 full-param 与 LoRA 两条路径。
        # 若只在 p2p 传输路径打戳，LoRA 加载后 sample.weight_versions
        # 仍停留在旧值，staleness 过滤会失去参照
        ray.get(
            [
                engine.update_weight_version.remote(weight_version=str(self.weight_version))
                for engine in self.rollout_engines
            ]
        )

```

```

    ]
)
end_weight_update(self.rollout_engines)
ray.get([engine.continue_generation.remote() for engine in self.rollout_engines])

```

评论区精华

核心讨论集中在两个问题上：

1. LoRA 路径的版本戳缺失 (P1, guapisolo) : reviewer 指出 `input.weight_version` 只有在与 `Sample.weight_versions` 同源时才可比；而单 LoRA + 默认 broadcast 传输路径 `load_lora_adapter_from_distributed` 不打任何 `weight_version`，样本会残留 "default" 或固定基础版本，导致 `oldest_weight_version` 要么返回 `None` 静默关闭过滤，要么固定不变直到整组被当成 stale 回收。作者通过把打戳统一进 `mixin._finalize_and_resume_engines` 解决（commit 信息即“stamp the engine weight version for every transport including LoRA”），但未按 reviewer 要求补 LoRA 专项测试。
 2. 容错切换下版本回退 (P2, guapisolo 的 issue 评论) : `weight_updater.weight_version` 是每个 actor 的内存计数器，不 checkpoint、不持久化；`--indep-dp` 下 `update_weights` 跑在第一个存活的 cell 上，cell 0 死后 cell 1 的计数器仍为 0，版本会从 57 回退到 1，已入队的旧版本样本使 `staleness = current - oldest` 变负，反而恰好把最 off-policy 的组放进训练。当前实现（`--indep-dp` 只告警）没有闭环该问题。
- LoRA 路径未打版本戳导致 staleness 参照失效 (correctness): 作者将引擎打戳统一上移到 `mixin._finalize_and_resume_engines`，覆盖 LoRA 与 full-param 路径（commit a4cb8d3）；但 reviewer 要求的 LoRA 专项测试未补充。
 - cell failover 下 `weight_version` 回退使 staleness 过滤静默失效 (design): `set_weight_version` 在 `--indep-dp` 下只告警不阻断，且 `RolloutManager.save/load` 不持久化版本号，P2 隐患未闭环。

风险与影响

- 风险：
 1. 容错切换版本回退 (P2 未闭环) : `set_weight_version` 在 `--indep-dp` 下仅 `logger.warning`，版本回退后 `_drain` 中 `staleness` 变负、过滤静默失效，`rollout/fully_async/{avg,max}_staleness` 指标也会出现负数。需要后续把版本计数纳入 `checkpoint` 或从引擎恢复。
 2. LoRA 路径缺专项测试：虽然打戳已统一到 `mixin._finalize_and_resume_engines`，若未来有 LoRA 传输路径绕过该 hook，P1 问题会复发；reviewer 明确要求补覆盖。
 3. 通知时序窗口： `set_weight_version` 在 `update_weights()` 返回（引擎已恢复生成）之后才到达，期间 `drain` 会少报 `staleness`；PR body 自述该窗口小于被替换的 1s TTL，但仍存在。
 4. 首轮语义变化：第一个权重更新前 `weight_version` 为 `None`，`staleness` 过滤显式关闭；这是有意为之，但若用户在预热阶段依赖过滤会误以为配置失效。- 影响：影响集中在 `fully-async rollout` 与权重更新链路：删除每 group 一次的 router HTTP 查询（含失败 2s 超时风险），`drain` 延迟更稳定；`RolloutManager` 与训练 actor 新增接口，

Megatron 与 FSDP 两个后端同步改动；RolloutFnTrainInput 契约扩展影响所有实验性 rollout 实现。对用户而言，staleness 过滤在首轮权重更新前被显式关闭、router 抖动不再降级为 None；对团队而言，这是为 #2030 把 staleness 控制下沉到数据缓冲区的前置清理。- 风险标记：核心 rollout 路径变更，容错切换版本回退未闭环，LoRA 路径缺专项测试，过滤静默关闭语义变化

关联脉络

- PR #2030 staleness control in fully-async data buffer (PR body 提及): PR body 明确说明本 PR 是 #2030 的前置：把 staleness 控制下沉到 fully-async 数据缓冲区并支付每次 HTTP 往返成本，本 PR 先消除该成本，独立合入 main。
- PR #1673 [feat] support sample rollout submission granularity to keep fully async concurrency: 同文件 miles/rollout/fully_async_rollout.py 的 fully-async 并发与回收机制持续演进，本 PR 在此基础上切换了 weight_version 的来源。
- PR #2235 feat(fsdps): support rollout routing replay (R3) for fsdp backend: 同样改动 miles/backends/experimental/fsdp_utils/actor.py，FSDP 后端的 rollout/ 权重更新集成是本 PR 需要保持对齐的上下文。