

PR #2576 完整报告

radixark/miles

fix: skip rollout construction for debug replay

合并时间: 2026-08-18 17:58

原文链接: <http://prhub.com.cn/radixark/miles/pull/2576>

执行摘要

- 一句话: 调试回放跳过 rollout 构造, 修复崩溃与 FT 误启动
- 推荐动作: 值得精读, 核心是“构造门控”与“生命周期门控”两个概念的分离: 用 `load_debug_rollout_data` 控制是否构造 rollout fn, 用 `_rollout_ft_enabled` 控制是否启动 rollout 侧的生命周期工作。关注作者对门控选择的对抗性论证 (为什么不是 `debug_train_only`), 以及 `EvalFleet.pin` 中探测委派的语义。建议后续为 `RolloutManager` 增加 `generate_rollout` is None 的显式类型保护, 避免 None 静默传播。

功能与动机

PR body 指出 release 运行在 stage-c-8-gpu-h200 上因 `GenerateState` 报 `TypeError: unsupported operand type(s) for *: int and NoneType` 崩溃; 根因是 #2522 让 class-based rollout 成为默认后, `RolloutManager.__init__` 急切构造 `InferenceRolloutFn`, 而 `replay` 运行 (`--load-debug-rollout-data`, 强制 `debug_train_only`) 故意留空 `rollout_num_gpus`。独立验证评论也确认了同一回归链: `GenerateState.__init__` 用 `args.sglang_server_concurrency * args.rollout_num_gpus // args.rollout_num_gpus_per_engine` 计算信号量, `rollout_num_gpus=None` 直接触发 `TypeError`。此外, `train-only FT` (`--ft-components train`) 仍激活 rollout 生命周期, 导致确定性比较出现 10 个 `MetricEvent` 偏差。

实现拆解

1. 回放构造门控: 在 `miles/ray/rollout/rollout_manager.py` 的 `RolloutManager.__init__` 中, 把非 legacy 分支改为先判断 `args.load_debug_rollout_data` is not None; 是则直接令 `generate_rollout` 和 `eval_generate_rollout` 为 None, 不再调用 `load_rollout_function`, 避免构造 `GenerateState`。同时把 `_get_rollout_data` 的判定从真值判断收紧为 `is not None`, 保证语义一致。
2. FT 生命周期统一门控: 新增实例属性 `self._rollout_ft_enabled = self.args.use_fault_tolerance and "rollout" in self.args.ft_components`, 并将健康监控启动、`_ci_fault_injection_pending` 初始化、`generate()` 中的 CI 故障注入条件都改用它; `_ci_fault_injection_pending` 现在始终先初始化, 再在启用 rollout FT 时置为 `args.ci_test`。
3. `EvalFleet` 探测委派: 在 `miles/ray/rollout/eval_fleet.py` 的 `EvalFleet` 中同步计算 `_rollout_ft_enabled`, 用于 `pin()` 决定是否自行 `probe_and_mark_dead()`——`train-only FT` 没有 `RolloutHealthMonitor`, 必须自己探测。

4. 训练端恢复收口：在 miles/ray/actor_group.py 的 RayTrainGroup.update_weights() 中，把 recover_updatable_engines 的调用条件从仅 use_fault_tolerance 收紧为同时要求 "rollout" in ft_components，避免 train-only FT 恢复 rollout 引擎。
5. 测试配套：tests/fast/ray/rollout/real_ray/test_rollout_manager.py 新增参数化测试验证 monitor 数量与故障注入 pending 跟随组件选择，并新增 replay 跳过构造 / train-only 正常构造两个用例；tests/fast/ray/test_actor_group_shared_ppo.py 新增 _RemoteCall 辅助类和 test_train_only_ft_does_not_recover_rollout_engines；
tests/fast/ray/rollout/test_eval_fleet.py 新增
test_fleet_probes_with_train_only_fault_tolerance，并调整既有用例的 ft_components 设置。

关键文件：

- miles/ray/rollout/rollout_manager.py（模块 回放管理；类别 source；类型 core-logic；符号 RolloutManager.init, RolloutManager._get_rollout_data, RolloutManager.generate）：核心修复文件：在 __init__ 中按 load_debug_rollout_data 跳过 class-based rollout 构造，避免 GenerateState 崩溃；并引入 _rollout_ft_enabled 统一门控健康监控、CI 故障注入与 _get_rollout_data 分支语义。
- tests/fast/ray/rollout/real_ray/test_rollout_manager.py（模块 回放测试；类别 test；类型 test-coverage；符号 test_rollout_ft_lifecycle_follows_selected_component, FakeMonitor, test_debug_rollout_replay_skips_class_based_rollout_construction, test_debug_train_only_without_replay_constructs_rollout_function）：覆盖三类回归场景：replay 跳过构造、train-only 不启动 monitor、rollout 组件启用 monitor 与故障注入；是门控行为的主要测试依据。
- miles/ray/rollout/eval_fleet.py（模块 评估集群；类别 source；类型 core-logic；符号 EvalFleet.init, EvalFleet.pin）：EvalFleet.pin 的探测委派逻辑随 _rollout_ft_enabled 调整，train-only FT 下必须自行 probe，否则引擎健康无法保证。
- miles/ray/actor_group.py（模块 训练组；类别 source；类型 core-logic；符号 RayTrainGroup.update_weights）：RayTrainGroup.update_weights 的引擎恢复条件收紧，避免 train-only FT 恢复 rollout 引擎，是生命周期门控在训练侧的关键落点。
- tests/fast/ray/rollout/test_eval_fleet.py（模块 评估测试；类别 test；类型 test-coverage；符号 test_fleet_probes_with_train_only_fault_tolerance）：新增 train-only FT 下 EvalFleet 自行探测的用例，并修正既有用例的 ft_components 设置。
- tests/fast/ray/test_actor_group_shared_ppo.py（模块 训练组测试；类别 test；类型 test-coverage；符号 _RemoteCall, test_train_only_ft_does_not_recover_rollout_engines）：新增 _RemoteCall 辅助类和 train-only FT 不恢复 rollout 引擎的用例，验证 update_weights 门控。

关键符号：RolloutManager.init, RolloutManager._get_rollout_data, RolloutManager.generate, EvalFleet.init, EvalFleet.pin, RayTrainGroup.update_weights, test_rollout_ft_lifecycle_follows_selected_component, test_debug_rollout_replay_skips_class_based_rollout_construction, test_train_only_ft_does_not_recover_rollout_engines, test_fleet_probes_with_train_only_fault_tolerance

关键源码片段

miles/ray/rollout/rollout_manager.py

核心修复文件：在 `__init__` 中按 `load_debug_rollout_data` 跳过 class-based rollout 构造，避免 `GenerateState` 崩溃；并引入 `_rollout_ft_enabled` 统一门控健康监控、CI 故障注入与 `_get_rollout_data` 分支语义。

```
# 回放模式下完全没有真实 rollout 函数调用，因此：
# - 若配置了 --load-debug-rollout-data，直接跳过 class-based rollout 构造，
# 避免 GenerateState 因 rollout_num_gpus=None 崩溃；
# - 否则才加载 rollout 函数（train-only SFT 也依赖它产出数据）。
self.use_legacy_rollout_v1 = use_legacy_rollout_v1()
if not self.use_legacy_rollout_v1:
    if self.args.load_debug_rollout_data is not None:
        self.generate_rollout = None
        self.eval_generate_rollout = None
    else:
        input = RolloutFnConstructorInput(args=args, data_source=self.data_source)
        self.generate_rollout = load_rollout_function(input, self.args.rollout_function_path)
        if self.args.eval_function_path == self.args.rollout_function_path:
            # eval 与 train 共享同一个有状态实例，避免 FullyAsyncRolloutFn 被构造两次
            self.eval_generate_rollout = self.generate_rollout
        else:
            self.eval_generate_rollout = load_rollout_function(input, self.args.eval_function_path)
    else:
        self.generate_rollout = load_function(self.args.rollout_function_path)
        self.eval_generate_rollout = load_function(self.args.eval_function_path)
# （custom reward / convert 函数加载已省略）

# rollout FT 生命周期只在显式勾选 rollout 组件时激活：
# train-only FT 不应启动健康监控、故障注入或引擎恢复。
self._rollout_ft_enabled = self.args.use_fault_tolerance and "rollout" in self.args.ft_components
self._ci_fault_injection_pending = False
if not self.args.debug_train_only and self._rollout_ft_enabled:
    for srv in self.servers.values():
        for group in srv.server_groups:
            monitor = RolloutHealthMonitor(group, args)
            monitor.start()
            self._health_monitors.append(monitor)
        self._ci_fault_injection_pending = self.args.ci_test
```

miles/ray/rollout/eval_fleet.py

`EvalFleet.pin` 的探测委派逻辑随 `_rollout_ft_enabled` 调整，train-only FT 下必须自行 probe，否则引擎健康无法保证。

```
class EvalFleet:
    """专用 in-job 评估引擎（--eval-num-gpus）的权重交付与健康管理。"""

    def __init__(self, args: Namespace, *, srv):
```

```

self.args = args
self._srv = srv
# 只有当 rollout 组件启用故障容忍时, RolloutHealthMonitor 才会负责探测;
# train-only FT 下没有 monitor, EvalFleet 必须自己 probe。
self._rollout_ft_enabled = args.use_fault_tolerance and "rollout" in args.ft_components
self._state = GenerateState(self._fleet_args())

```

```

async def pin(self, checkpoint_dir: str, weight_version: str) -> GenerateState:
    """把快照加载到每个评估引擎, 并返回可生成的状态。

```

```

    在 manager 事件循环上运行, 全程 await 而非阻塞。
    """

```

```

    try:
        if not self._rollout_ft_enabled:
            # 没有 monitor 接管时, 先探测并标记死引擎, 再恢复, 再等待全部存活
            await self._srv.probe_and_mark_dead()
            await self._srv.recover()
            await self._srv.wait_all_engines_alive()
        except Exception as e:
            logger.warning(f"Eval fleet unhealthy: {e}")
            raise EvalSkip("unhealthy") from e

```

```

    if not await self._pin_fleet(checkpoint_dir, weight_version):
        raise EvalSkip("pin_violation")

```

```

    try:
        await self._wait_router_ready()
    except Exception as e:
        logger.warning(f"Eval router not ready: {e}")
        raise EvalSkip("unhealthy") from e

```

```

    return self._state

```

评论区精华

作者 guapisolo 在 issue 评论中给出了完整回归链: [#2522](#) 使 class-based rollout fn 成为默认后, `RolloutManager.__init__` 急切构造 `InferenceRolloutFn`, replay 又故意留空 `rollout_num_gpus`, 于是构造期即崩溃; 并解释了为什么 `load_debug_rollout_data` 是正确的门控而 `debug_train_only` 是错的: 独立 SFT 运行 (如 `scripts/run_qwen3_sft.py`、`examples/geo3k_vlm/run_geo3k_vlm_sft.sh`) 把 rollout fn 当作实际数据生产者, `_get_rollout_data` 只绕过 `generate_rollout` 而不绕过构造。

CI 验证过程被多次更新: 初始未验证 → 推送修复后开始验证 → 最终主栈未经 override 的情况下 28 passed / 2 skipped / 0 failed, 之前失败的 `test_trainer_ft_deterministic_dp2_cp2_real_rollout.py` 通过。另有独立验证从 release-cut 失败出发、未参考本 PR 即收敛到同一 gate。

reviewer fzyzcjy 批准: "LGTM for trainer-ft related changes, since I refactor a lot in <https://github.com/radixark/miles/issues/1837>".

- 回放门控选择: `load_debug_rollout_data` 而非 `debug_train_only (design)`: 采用 `load_debug_rollout_data` 作为构造门控, 普通 `train-only` 仍构造 rollout fn。
- `train-only FT` 不应激活 rollout 生命周期 (`correctness`): 引入 `_rollout_ft_enabled` 统一门控, `monitor`、故障注入、恢复均受控。
- CI 验证状态确认 (`testing`): 验证完成, PR 可合并。
- 独立验证结论一致 (`question`): 确认修复方向正确。
- `trainer-ft` 相关改动批准 (`other`): 批准本 PR。

风险与影响

- 风险: 核心路径变更: `RolloutManager.__init__` 是所有训练 / 回放共用的初始化路径, 门控改动影响面广; 若未来新增调用方直接使用 `generate_rollout` 而忘记检查回放标志, 会触发 `None` 调用错误。

配置语义收紧: `load_debug_rollout_data` 从真值判断改为 `is not None`, 若历史配置传空字符串或 `0` (非 `None` 但 `falsy`), 行为会反转; 不过该参数预期是路径字符串, 实际风险低。

FT 组件依赖: `_rollout_ft_enabled` 依赖 `args.ft_components` 为有效可迭代且包含 `"rollout"`; 若外部配置未正确初始化 `ft_components` (如 `None`), `"rollout" in None` 会抛 `TypeError`。需要确认参数解析的默认值。

`train-only FT` 下 `EvalFleet` 自行 `probe` 会增加一次探测开销, 但每次 `pin` 才一次, 影响很小; `RayTrainGroup.update_weights` 不再在 `train-only FT` 时恢复 rollout 引擎, 若训练端依赖引擎预先恢复可能漏恢复, 但 `train-only FT` 语义上本就不应触碰 rollout。

现有测试未覆盖 `legacy rollout v1` 路径, 只能依赖环境变量门控保证。

- 影响: 对用户: 使用 `--load-debug-rollout-data` 的调试回放不再崩溃; 使用 `--ft-components train` 的确定性 FT 测试不再被 rollout 生命周期污染, `MetricEvent` 对比可通过。

对系统: 修复了 `release-branch-cut` 的阻塞问题, 作者明确表示合并此 PR 是重切 `release` 的前提。

对团队: FT CI 稳定收敛, 后续可在干净的组件门控上继续推进完整 FT 能力; 测试新增三组用例, 为回放与 `train-only` 行为提供了长期防护网。

- 风险标记: 核心路径变更, 配置语义收紧, FT 组件依赖新字段, 缺少 `legacy` 路径测试

关联脉络

- PR #2522 Make the class-based rollout the default and convert legacy path to env var gated: 回归源头: 该 PR 使 `RolloutManager.__init__` 急切构造 class-based rollout fn, 从而在 `replay` 时触发 `GenerateState TypeError`。