

PR #1856 完整报告

THUDM/slime

refactor/ppo

合并时间: 2026-04-24 23:00

原文链接: <http://prhub.com.cn/THUDM/slime/pull/1856>

执行摘要

- 一句话: PPO 训练架构重构, 解耦 actor-critic 配置与通信
- 推荐动作: 建议 PPO 训练用户深入阅读本 PR, 理解新的 critic 配置和训练循环模型。值得关注的设计决策包括: 移除 NCCL 同步改为 Ray 数据传递, 以及强制 critic 与 actor 共享 GPU。这些设计简化了部署但损失了部分灵活性, 需根据实际场景评估。

功能与动机

根据 PR 描述, 此次重构为后续功能铺路, 包括支持 actor 和 critic 不同并行配置、多 critic 等。当前架构中 actor 和 critic 强耦合, 通过 NCCL 通信同步数据, 限制了灵活性和扩展性。通过引入独立配置和异步 Ray 传参, 实现解耦。

实现拆解

1. 引入 critic 独立配置机制: 在 `slime/utils/arguments.py` 中新增 `parse_critic_args` 函数, 通过 `--critic-config-path` 指定 YAML 文件, 允许批评者拥有独立的 TP/PP 等并行配置。同时移除了旧的 `--critic-load`、`--critic-save`、`--critic-lr` 等独立 CLI 参数, 保留 `--num-critic-only-steps`。新增 `--custom-advantage-function-path` 支持自定义优势函数。在 `slime/backends/megatron_utils/arguments.py` 中移除 `critic_num_nodes/critic_num_gpus_per_node` 相关逻辑, 强制批评者与行动者共享相同的 GPU 资源。
2. 移除 actor-critic 间的 NCCL 进程组同步: 在 `slime/backends/megatron_utils/data.py` 中删除 `sync_actor_critic_data` 函数, 该函数通过 `dist.broadcast` 在 actor 和 critic 之间同步 `values`、`log_probs` 等张量。取而代之的是新增 `tensors_to_cpu` 和 `tensors_to_gpu` 工具函数, 用于将张量移出 / 移入 GPU, 以便通过 Ray 对象存储传递。在 `slime/backends/megatron_utils/actor.py` 的 `train` 方法中新增 `external_data` 参数, 用于接收批评者传递的值。`train_critic` 方法返回 CPU 上的 `values` 字典, `train_actor` 则使用 `external_data` 中提供的 `values` 进行计算。
3. 重构训练循环与 Ray 传输层: 在 `train.py` 中修改训练循环: 批评者先执行 `async_train` 并获取 `value_refs` (Ray 对象引用), 然后行动者训练时通过 `external_data=value_refs` 传递这些值。移除了 `critic_train_only` 条件分支, 统一将 `actor_trains_this_step` 作为是否训练行动者的标志。在 `train_async.py` 中相应调整。在 `slime/ray/actor_group.py` 中修改 `async_train` 接口以支持 `external_data`, 支持单个字典或列表形式。同时移除了 `connect` 方法, 因为不再需要建立 NCCL 连接。

4. 调整资源分配与验证逻辑：在 `slime/ray/placement_group.py` 中，不再为批评者单独创建 placement group，而是与行动者共享同一组 GPU。`create_placement_groups` 返回的字典中 `critic` 键直接引用 `actor`。相应的，`_compute_rollout_offset` 等辅助函数移除了批评者相关的偏移计算。
5. 配套更新：更新了 `examples/geo3k_vlm_multi_turn/run_geo3k_vlm_multi_turn_ppo_npu.py` 以适配新的参数接口。同时在 `slime/backends/megatron_utils/loss.py` 中新增自定义优势函数支持，允许用户通过 `--custom-advantage-function-path` 提供自定义函数。

关键文件：

- `slime/backends/megatron_utils/actor.py`（模块 训练核心；类别 source；类型 core-logic；符号 `train`, `train_critic`, `train_actor`, `connect_actor_critic`）：核心训练逻辑重构，修改了 `train`、`train_critic`、`train_actor` 方法，新增 `external_data` 参数，移除了 `connect_actor_critic` 连接逻辑。
- `slime/backends/megatron_utils/data.py`（模块 数据传输；类别 source；类型 core-logic；符号 `sync_actor_critic_data`, `tensors_to_cpu`, `tensors_to_gpu`）：移除 `sync_actor_critic_data` 函数，新增 `tensors_to_cpu` 和 `tensors_to_gpu` 作为张量传输替代方案。
- `slime/Utils/arguments.py`（模块 参数配置；类别 source；类型 dependency-wiring；符号 `parse_critic_args`）：新增 `parse_critic_args` 函数解析批评者 YAML 配置，移除旧 CLI 参数，新增 `--custom-advantage-function-path`。
- `train.py`（模块 训练入口；类别 source；类型 core-logic；符号 `offload_train`）：修改训练循环以支持新数据流，重构 `offload_train` 和 `save` 逻辑，传递 `external_data`。
- `slime/ray/actor_group.py`（模块 通信层；类别 source；类型 core-logic；符号 `async_train`, `connect`）：修改 `async_train` 以支持 `external_data` 参数，移除 `connect` 方法，适配新训练流程。
- `slime/ray/placement_group.py`（模块 资源调度；类别 source；类型 dependency-wiring）：修改资源分配，批评者与行动者共享 placement group，移除独立批评者 GPU 计算。
- `slime/backends/megatron_utils/loss.py`（模块 优势计算；类别 source；类型 core-logic）：添加自定义优势函数支持，在 `compute_advantages_and_returns` 中调用。
- `train_async.py`（模块 异步训练；类别 source；类型 core-logic）：适配训练循环变化，移除了 `critic_train_only` 条件。

关键符号：`train`, `train_critic`, `train_actor`, `connect_actor_critic`, `sync_actor_critic_data`, `tensors_to_cpu`, `tensors_to_gpu`, `parse_critic_args`, `offload_train`, `async_train`, `connect`, `compute_advantages_and_returns`

关键源码片段

`train.py`

修改训练循环以支持新数据流，重构 `offload_train` 和 `save` 逻辑，传递 `external_data`。

```
def offload_train(actor_trains_this_step):
    # 每个模型在 train() 之后自动卸载（当 offload_train 开启时），
    # 所以非 offload 情况下我们只需要清理内存即可。
```

```
if not args.offload_train:
    if not args.use_critic or actor_trains_this_step:
        actor_model.clear_memory()
    else:
        critic_model.clear_memory()
```

评论区精华

- 批评者值映射与并行限制: @Copilot 指出 `critic_values_by_actor_worker` 在非 last-PP-stage 工人键缺失时可能引发 `KeyError`。@zhuzilin 回应“如果只支持相同并行配置，可以简单传递数据，将复杂映射留给未来 PR”。当前仅支持相同配置，风险未完全解除。
- 资源调度风险: @Copilot 警告批评者与行动者共享 placement group 可能导致资源碎片 / 死锁。@zhuzilin 直接接受共享方案 (`result["critic"] = result["actor"]`)，认为当前可行。
- 代码健壮性: @Copilot 建议将 `parse_critic_args` 中的 `assert` 替换为 `ValueError` 以免禁用断言时静默失败。未见采纳。
- 传递方式设计: @zhuzilin 建议在训练循环中直接传递 `value_refs` (Ray ref) 而非在控制进程中具体化。最终代码采用了此方式。
- 命名规范: @zhuzilin 要求遵循 `--custom-xxx-function-path` 命名约定，作者已调整。
- 未解疑虑: @zhuzilin 询问关闭 `normalize advantage` 的原因，无回复。
 - `critic_values_by_actor_worker` 潜在的 `KeyError (correctness)`: 当前仅支持 actor 和 critic 相同并行配置，问题未完全解决但可接受。
 - 资源调度死锁风险 (performance): 接受共享，当前资源分配方式不改。
 - 训练循环中值传递方式 (design): 最终代码采用直接传递 `value_refs` 作为 `external_data`，符合建议。
 - 参数命名约定 (style): 作者调整了参数名 (从 `--custom-advantage-fn` 改为 `--custom-advantage-function-path`)。
 - 为什么关闭 `advantage` 归一化 (question): 无回复，原因不明。

风险与影响

- 风险:
 1. 数值一致性风险: 移除 NCCL broadcast 后，批评者值通过 Ray 对象存储 (CPU) 传递，再移回 GPU 时 `tensors_to_gpu` 转为 `float32`，可能引入精度差异，需验证 PPO 梯度更新不受影响。
 2. 资源调度死锁风险: 批评者 placement group 引用行动者的 PG，在资源紧张时可能发生 gang scheduling 失败，建议增加重试或超时机制。
 3. 配置接口断裂: 旧脚本若使用 `--critic-load` 等参数将失败，需要用户迁移到 YAML 配置文件。
 4. 自定义优势函数缺少验证: 若用户提供的函数未正确设置 `rollout_data['advantages']`，后续代码将抛出 `KeyError`，定位困难。
 5. 代码路径覆盖: 训练循环中的 `actor_trains_this_step` 逻辑改动可能影响 critic-only 或 PPO 配置特定阶段的行为，需要更全面的集成测试。

- 影响:

- 用户影响: 现有 PPO 训练用户需更新启动脚本以使用 `--critic-config-path` 替代旧的 `critic` 参数。自定义优势函数新增钩子提供扩展点。
- 系统影响: 训练数据流从 GPU NCCL 改为 CPU Ray 传输, 可能增加端到端延迟但降低 GPU 间耦合, 便于未来支持异构并行。
- 团队影响: 架构更加清晰, 为后续多 critic、异步训练等特性打下基础。但重构范围广, 需谨慎回归。
- 影响程度: 中等, 主要涉及训练核心路径, 不影响推理 /eval 流程。
- 风险标记: 训练循环重构, NCCL 同步移除, 资源调度变化, 配置接口变更, 自定义优势函数未验证

关联脉络

- PR #1805 sync from internal: 涉及 Megatron model provider 和 SGLang rollout 的同步, 与本 PR 的训练重构在同一功能线上。
- PR #1807 sync from internal: 涉及 Megatron model forward 参数构建, 与本 PR 的训练核心改动有联系。