

PR #2266 完整报告

THUDM/slime

Refactor --save-debug-train-data

合并时间: 2026-08-12 17:50

原文链接: <http://prhub.com.cn/THUDM/slime/pull/2266>

执行摘要

- 一句话: 重构 `--save-debug-train-data` 为单文件转储并支持 CP 恢复
- 推荐动作: 值得精读。重点看 `restore_context_parallel_fields_to_cpu` 的逐 sample gather 与显存控制、`policy_loss_function` 中的捕获钩子设计, 以及 `_build_dump_payload` 的排序与布局。对需要扩展训练数据转储或理解 Megatron 后端 CP/PP 数据流转的工程师有直接参考价值。

功能与动机

PR body 为空, 动机可从代码注释和提交信息还原。旧实现每 rank 各写一个文件, 样本顺序与 rollout dump 不对齐, 无法逐样本比对; CP 开启时 response 级字段只有本 rank 局部片段, 落盘数据不可直接用; 当配置跳过单独 log-prob 重算 (`can_reuse_log_probs_in_loss / use_rollout_logprobs`) 时转储拿不到 per-sample log_probs, 需要额外 forward。新实现希望在不跑 forward、不显著抬高显存峰值的前提下, 产出与 rollout dump 严格对齐的规范化 train dump。

实现拆解

1. 转储核心迁移与重建: 新增 `slime/backends/megatron_utils/train_dump_utils.py`, 删除 `slime/utils/train_dump_utils.py`。新的 `save_debug_train_data` 只由“最后一个 PP stage + TP rank 0 + CP rank 0”的 writer rank 写盘; `_build_dump_payload` 把 DP gather 到的各 rank 载荷整理成与 rollout dump 对齐的结构: `samples` 按 `partition` 优先排序、`sample_indices` 兜底; `micro_batch_indices`、`num_microbatches`、`global_batch_sizes` 等布局字段挂在 `dp_shards` 键下, 避免复制 per-sample 张量。
2. CP 字段逐步恢复与显存控制: `restore_context_parallel_fields_to_cpu` 遍历 `_CONTEXT_PARALLEL_FIELDS` (共 10 个 response 级字段, 如 `rollout_log_probs`、`values`、`advantages`、`returns`) 逐 sample 调用 `gather_tensor(value, total_length, response_length)` 恢复完整序列; `keep_restored` 只对 writer rank 生效, 其余 rank 跑完集合通信即丢弃结果, 每次 gather 后立刻 `del full_value`, 把额外设备显存峰值压到“一个 response 张量”以内。
3. 训练期 log-prob 捕获: `slime/backends/megatron_utils/loss.py` 新增模块级 `_LOG_PROB_CAPTURE` 及 `enable_log_prob_capture`、`drain_captured_log_probs`、`_maybe_capture_log_probs`; `policy_loss_function` 在 `torch.cat` 重绑定 `log_probs` 之前调用捕获钩子, 按全局 `partition` 位置保存 CP-local 张量, “首次出现优先”保证多 step 训

练保留 old-policy 值。`actor.py` 的 `train_actor` 在开启 `dump` 且 `rollout_data` 缺少 `log_probs` 时启用捕获, train 结束后以本地 `partition` 顺序还原注入 `rollout_data["log_probs"]`。

4. 数据契约与配置联动: `slime/utils/data.py` 在 `dump` 模式下向训练数据注入 `partition` 键; `model.py` 配合格式版本控制; `arguments.py` 微调参数语义; `dump` 文件改为 `format_version=2`, 单文件同时含 `samples` 和 `dp_shards` 两个顶层键。
5. 测试、CI 与文档: 新增 `tests/test_train_dump.py` (真实集合通信的 CP 恢复、DP 分片单文件写入、无 CP 归一化格式) 与 8 GPU e2e `tests/test_qwen2.5_0.5B_debug_train_dump_e2e.py` (TP=2、PP=2、CP=2、DP=1, 按 `rollout_position` 连接两份 `dump` 并逐样本比对 `rollout_log_probs`) ; `pr-test.yml` 及其模板注册新测试, `docs/en/developer_guide/debug.md` 补充新格式说明。

关键文件:

- `slime/backends/megatron_utils/train_dump_utils.py` (模块 转储工具; 类别 source; 类型 dependency-wiring; 符号 `_to_cpu`, `restore_context_parallel_fields_to_cpu`, `_is_per_sample`, `_build_dump_payload`) : 转储核心实现, 从 `slime/utils` 迁入并重写为单文件格式; 包含 CP 字段恢复、payload 构建与 writer 选择逻辑, 是本 PR 的主体。
- `slime/backends/megatron_utils/loss.py` (模块 损失函数; 类别 source; 类型 core-logic ; 符号 `enable_log_prob_capture`, `drain_captured_log_probs`, `_maybe_capture_log_probs`) : 在策略损失主路径新增可选 log-prob 捕获钩子, 使 `dump` 在复用训练 forward 时零额外开销拿到 per-sample log-probs。
- `slime/backends/megatron_utils/actor.py` (模块 训练器; 类别 source; 类型 dependency-wiring; 符号 `train_actor`) : 接线点: 根据 `save_debug_train_data` 与 `rollout_data` 是否含 `log_probs` 决定是否开启捕获, train 后按 `partition` 还原并注入。
- `tests/test_train_dump.py` (模块 单元测试; 类别 test; 类型 test-coverage; 符号 `_patch_single_dp_writer`, `_restore_context_parallel_worker`, `_single_file_dump_worker`, `test_restore_context_parallel_fields_with_real_collective`) : 覆盖新转储核心: 真实集合通信 CP 恢复、DP 分片单文件写入、无 CP 归一化格式。
- `tests/test_qwen2.5_0.5B_debug_train_dump_e2e.py` (模块 端到端测试; 类别 test; 类型 test-coverage; 符号 `prepare`, `_train_args`, `_verify`, `execute`) : 8 GPU 端到端验证: TP/PP/CP 全开, 连接 rollout 与 train dump 逐样本比对 `rollout_log_probs`。
- `slime/utils/train_dump_utils.py` (模块 转储工具; 类别 source; 类型 deletion; 符号 `save_debug_train_data`) : 旧实现被删除, 逻辑迁移至 `megatron_utils` 下的新文件。

关键符号: `save_debug_train_data`, `restore_context_parallel_fields_to_cpu`, `_build_dump_payload`, `_to_cpu`, `_is_per_sample`, `enable_log_prob_capture`, `drain_captured_log_probs`, `_maybe_capture_log_probs`

关键源码片段

`slime/backends/megatron_utils/loss.py`

在策略损失主路径新增可选 log-prob 捕获钩子, 使 `dump` 在复用训练 forward 时零额外开销拿到 per-sample log-probs。

```
# 训练 forward 中产生的 per-sample log-probs 快照，按全局 rollout position 索引。  
# 只在需要 dump 且复用训练 forward 的 log-probs 时启用，避免额外 forward。  
_LOG_PROB_CAPTURE: "dict[int, torch.Tensor] | None" = None
```

```
def enable_log_prob_capture() -> None:  
    """开启捕获，必须在 train 之前调用。"""  
    global _LOG_PROB_CAPTURE  
    _LOG_PROB_CAPTURE = {}
```

```
def drain_captured_log_probs() -> "dict[int, torch.Tensor]":  
    """取走捕获结果并停止捕获；未捕获时返回空 dict。"""  
    global _LOG_PROB_CAPTURE  
    captured = _LOG_PROB_CAPTURE or {}  
    _LOG_PROB_CAPTURE = None  
    return captured
```

```
def _maybe_capture_log_probs(batch: RolloutBatch, log_probs: list[torch.Tensor]) -> None:  
    """在 policy_loss_function 中快照 per-sample CP-local log-probs。
```

仅在捕获开启且 batch 携带 partition 时工作；partition 只在 dump 模式下被注入训练数据。每个 position 保留首次出现的值（old-policy），多 step 训练因此不会覆盖初始策略的 log-probs。

```
    """  
    if _LOG_PROB_CAPTURE is None:  
        return  
    positions = batch.get("partition")  
    if not positions:  
        return  
    for position, log_prob in zip(positions, log_probs, strict=True):  
        if position not in _LOG_PROB_CAPTURE:  
            _LOG_PROB_CAPTURE[position] = log_prob.detach().clone()
```

评论区精华

本 PR 没有 review 评论或讨论线程（comments_count=0、review_comments_count=0）。设计取舍体现在代码注释与提交信息中：单文件格式中 **dp_shards** 布局单独存放，是为了与 rollout debug dump 的扁平 **samples** 视图对齐而不复制 per-sample 张量；writer 只由“last PP stage + TP0 + CP0”承担，e2e 测试专门覆盖该选取逻辑；**keep_restored** 仅在 writer 上保留 CPU 值并配合 **del full_value** 控制显存峰值，是最值得借鉴的写法。

- 暂无高价值评论线程

风险与影响

- 风险：

1. 核心训练路径改动: `loss.py` 的 `policy_loss_function` 是训练主路径, `_maybe_capture_log_probs` 的新分支必须保证默认关闭时零开销、零行为变化; 注释明确要求钩子在 `torch.cat` 重绑定 `log_probs` 之前执行, 后续维护需保持此顺序。
2. 多 rank 状态管理: 模块级 `_LOG_PROB_CAPTURE` 依赖 `actor.py` 的对称启停; 若 `train` 异常退出未调用 `drain_captured_log_probs`, 可能残留旧状态, 建议补充异常路径清理。
3. 新增 CP 集合通信: `restore_context_parallel_fields_to_cpu` 对每个 CP 字段逐个 `sample gather`, 字段多时通信次数线性增加; 虽有 `del` 控制显存, 通信延迟对训练循环仍可能有扰动, 目前仅在 `dump` 模式启用。
4. 数据格式契约变更: `dump` 产物从“每 rank 一个文件”变为“单文件 + `format_version=2`”, 依赖旧格式的调试脚本需要迁移; `partition` 键只在 `dump` 模式注入, 正常训练数据契约不变。
5. e2e 覆盖有限: 8 GPU e2e 覆盖 `TP=2/PP=2/CP=2/DP=1`, 未覆盖 `DP>1` 与 CP 同时存在的组合 (单元测试用 4 进程模拟 `DP=2/CP=2`)。 - 影响: 影响范围集中在 Megatron 后端训练调试链路: 使用 `--save-debug-train-data` 的用户会拿到格式变更后的产物 (单文件、`format_version=2`), 需要相应调整调试脚本; 新 `log-prob` 捕获仅在开启 `dump` 且复用训练 `forward` 时生效, 对正常运行无感知; CI 增加 8 GPU e2e 测试成本; 团队后续可以用同一份规范化 `dump` 直接对齐 rollout 与 train 数据, 降低排查策略 / 奖励不一致的难度。 - 风险标记: 核心训练路径改动, 数据格式契约变更, 新增 CP 集合通信, 多 rank 状态管理

关联脉络

- PR #2247 fix: forward dual-clip PPO epsilon: 同改 `slime/backends/megatron_utils/loss.py`, 都在训练损失主路径上做配置 / 数据接线。
- PR #2234 fix: pair `--log-correct-samples` rewards with the DP-local samples: 同改 `slime/utils/data.py`, 都处理 DP 切分下样本与张量的对齐问题。
- PR #2205 perf: vectorize REINFORCE++ discounted returns: 同属训练工具链数值逻辑重构, 并配套新增测试, 反映该区域的持续演进。