

PR #1920 完整报告

THUDM/slime

Move fully_async example to main codebase

合并时间: 2026-05-18 19:46

原文链接: <http://prhub.com.cn/THUDM/slime/pull/1920>

执行摘要

- 一句话: 将 fully_async rollout 从示例迁移至主代码库, 新增 `slime.rollout.fully_async_rollout` 模块
- 推荐动作: 值得精读, 展示了如何将实验性代码正式合入主库的标准化流程: 代码迁移、类型标注增强、测试配套、文档更新、CI 集成。其中全局 worker 单例和 ABORTED 样本重定向的设计值得借鉴。

功能与动机

PR 将 fully_async rollout 从示例代码迁移到主代码库, 使其成为 slime 的标准 rollout 方案之一。用户可通过 `--rollout-function-path` 直接使用, 无需复制示例代码。同时, 该模式通过后台线程保持 in-flight 轨迹, 减少训练等待, 提升训练吞吐。

实现拆解

1. 删除 `examples/fully_async/fully_async_rollout.py`, 将其核心逻辑 (AsyncRolloutWorker 类、全局 worker 管理) 迁移到 `slime/rollout/fully_async_rollout.py`, 并优化了并发计算 (考虑 engine 数量)。
2. 修改 `slime/rollout/sglang_rollout.py` 中 `generate_and_rm_group` 的返回类型标注, 支持 `list[Sample] | list[list[Sample]]`, 以适应 multi-turn agent rollout 的扇出场景。
3. 新增 CI 测试 `tests/test_qwen2.5_0.5B_fully_async_short.py`, 在 Qwen2.5-0.5B 模型上执行 3 轮 GRPO 以验证 end-to-end 路径。
4. 更新 `examples/fully_async/` 下的启动脚本 (新增 `run-qwen2.5-0.5B-fully_async.sh`, 删除旧的 `run-qwen3-4b-fully_async.sh`) 和 README, 指导用户如何使用新模块。
5. 在 CI 配置文件 `.github/workflows/pr-test.yml` 和 `.jinja2` 模板中注册新测试。

关键文件:

- `slime/rollout/fully_async_rollout.py` (模块 异步 rollout; 类别 source; 类型 core-logic; 符号 `_get_global_worker`, `_stop_global_worker`, `AsyncRolloutWorker`, `init`): 核心新模块, 实现 fully-async rollout 的后台 worker
- `slime/rollout/sglang_rollout.py` (模块 生成奖励; 类别 source; 类型 core-logic; 符号 `generate_and_rm_group`): 修改 `generate_and_rm_group` 的返回类型, 支持 multi-turn 扇出

- tests/test_qwen2.5_0.5B_fully_async_short.py (模块 集成测试; 类别 test; 类型 test-coverage; 符号 prepare, execute) : 新增 CI 测试, 验证 fully-async rollout 端到端路径
- examples/fully_async/fully_async_rollout.py (模块 示例脚本; 类别 source; 类型 deletion; 符号 get_global_worker, stop_global_worker, AsyncRolloutWorker, init) : 旧实现, 被删除, 内容迁移至 slime/rollout/ 中
- examples/fully_async/README.md (模块 文档; 类别 docs; 类型 documentation) : 更新文档, 反映新的模块路径和使用方式

关键符号: `_get_global_worker`, `_stop_global_worker`, `AsyncRolloutWorker`, `start`, `stop`, `get_completed_groups`, `queue_size`, `generate_rollout_fully_async`, `generate_and_rm_group`

关键源码片段

slime/rollout/fully_async_rollout.py

核心新模块, 实现 fully-async rollout 的后台 worker

全局 worker 单例, 跨 rollout 调用共享, 保持后台队列持续运行

`_global_worker: AsyncRolloutWorker | None = None`

`_worker_lock = threading.Lock()`

`def _get_global_worker(args, data_buffer) -> AsyncRolloutWorker:`

"""获取或创建全局异步 worker。

根据 args 中的 sglang 并发度和引擎数量计算并发度, 确保与 sglang_rollout 的 per-sample 信号量上限匹配。

"""

`global _global_worker`

`with _worker_lock:`

`if _global_worker is None or not _global_worker.worker_thread.is_alive():`

`logger.info("starting fully-async rollout worker")`

`num_engines = max(1, args.rollout_num_gpus // args.rollout_num_gpus_per_engine)`

`_global_worker = AsyncRolloutWorker(`

`args, data_buffer, concurrency=args.sglang_server_concurrency * num_engines`

`)`

`_global_worker.start()`

`return _global_worker`

`def _stop_global_worker() -> None:`

"""停止全局 worker, 在进程退出时自动调用。"""

`global _global_worker`

`with _worker_lock:`

`if _global_worker is not None:`

`_global_worker.stop()`

`_global_worker = None`

```
atexit.register(_stop_global_worker)
```

```
class AsyncRolloutWorker:
```

```
    """后台线程 + asyncio 事件循环，持续从 data_buffer 消费样本并调用 generate_and_rm_group。"""
```

```
    def __init__(self, args, data_buffer, concurrency: int = 10):
```

```
        self.args = args
```

```
        self.data_buffer = data_buffer
```

```
        self.concurrency = concurrency
```

```
        self.running = True
```

```
        self.output_queue: queue.Queue[tuple[int, list[Sample]]] = queue.Queue(maxsize=1000)
```

```
        self.worker_thread: threading.Thread | None = None
```

```
        self.state = GenerateState(args)
```

```
    def start(self) -> None:
```

```
        if self.worker_thread is None or not self.worker_thread.is_alive():
```

```
            self.worker_thread = threading.Thread(target=self._thread_main, name="fully-async-rollout", daemon=True)
```

```
            self.worker_thread.start()
```

```
    def stop(self) -> None:
```

```
        self.running = False
```

```
        if self.worker_thread and self.worker_thread.is_alive():
```

```
            self.worker_thread.join(timeout=5)
```

```
    def get_completed_groups(self) -> list[tuple[int, list[Sample]]]:
```

```
        completed: list[tuple[int, list[Sample]]] = []
```

```
        while True:
```

```
            try:
```

```
                completed.append(self.output_queue.get_nowait())
```

```
            except queue.Empty:
```

```
                break
```

```
        return completed
```

```
    def queue_size(self) -> int:
```

```
        return self.output_queue.qsize()
```

```
    def _thread_main(self) -> None:
```

```
        asyncio.run(self._loop())
```

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

```
        # 连续工作循环；具体实现与旧版 continuous_worker_loop 类似，
```

```
        # 但使用 self.concurrency 代替 rollout_batch_size 控制最大并发数，
```

```
        # 并将 ABORTED 样本重新放回 data_buffer。
```

```
        # 完整代码见提交后的文件。
```

```
        pass
```

slime/rollout/sglang_rollout.py

修改 generate_and_rm_group 的返回类型，支持 multi-turn 扇出

```
async def generate_and_rm_group(
    args: Namespace, group: list[Sample], sampling_params: dict[str, Any], evaluation: bool =
    False
) -> list[Sample] | list[list[Sample]]:
    # ``generate_and_rm`` may return either a ``Sample`` or a ``list[Sample]``
    # depending on whether the ``--custom-generate-function-path`` callable
    # emits one trainable sample or several (e.g. multi-turn agent rollouts
    # that fan out into multiple prefix-chained samples). The asyncio.gather
    # below preserves whichever shape each task produced, so the group is
    # ``list[Sample]`` for plain rollouts and ``list[list[Sample]]`` for
    # the fan-out case.
    state = GenerateState(args)
    # ... 其余函数体未变
```

tests/test_qwen2.5_0.5B_fully_async_short.py

新增 CI 测试，验证 fully-async rollout 端到端路径

```
def execute():
    ckpt_args = f"--hf-checkpoint /root/models/{MODEL_NAME}/ " f"--ref-load /root/models/
    {MODEL_NAME}/ "

    rollout_args = (
        # 唯一与 test_qwen2.5_0.5B_async_short.py 不同的行：
        # 使用公共的全异步 rollout 函数。
        "--rollout-function-path slime.rollout.fully_async_rollout.generate_rollout_fully_async "
        "--prompt-data /root/datasets/dapo-math-17k/dapo-math-17k.jsonl "
        "--input-key prompt "
        "--label-key label "
        "--apply-chat-template "
        "--rollout-shuffle "
        "--rm-type deepscaler "
        "--num-rollout 3 "
        "--rollout-batch-size 8 "
        "--n-samples-per-prompt 4 "
        "--rollout-max-response-len 8192 "
        "--rollout-temperature 0.8 "
        "--global-batch-size 32 "
        "--balance-data "
    )
    # ... 其他参数组合
    train_args = f"{ckpt_args} {rollout_args} {optimizer_args} {grpo_args} ..."
    U.execute_train(
        train_args=train_args,
        num_gpus_per_node=NUM_GPUS,
        megatron_model_type=MODEL_TYPE,
        train_script="train_async.py",
```

)

评论区精华

无 review 评论，PR 由作者自行合入。

- 暂无高价值评论线程

风险与影响

- 风险：主要风险在于新模块的 worker 生命周期管理：全局 worker 使用线程和 asyncio，若未正确停止可能导致资源泄漏；ABORTED 样本重定向逻辑依赖 data_buffer 的正确行为；并发度计算依赖 sglang 引擎数量，配置错误可能引起性能下降。此外，新增的 CI 测试仅在特定模型下运行，覆盖有限。
- 影响：对用户而言，fully_async rollout 成为一级特性，可通过命令行参数直接使用；旧示例路径（如 fully_async_rollout.generate_rollout_fully_async）不再可用，需改为 slime.rollout.fully_async_rollout.generate_rollout_fully_async。对系统而言，后台 worker 线程在训练周期之间持续运行，可能略微增加显存占用，但显著降低 rollout 等待时间。对团队而言，维护成本增加一个核心模块，但测试覆盖降低了回归风险。
- 风险标记：核心路径变更，并发控制复杂度，测试覆盖有限，生命周期管理

关联脉络

- PR #1890 Add missing metrics to log: 都与 rollout 日志和性能监控相关
- PR #1873 Use Ray ObjectRef await instead of asyncio.to_thread: 都涉及异步 rollout 优化