PR #42042 完整报告

vllm-project/vllm

[CI][Examples][RLHF] Disable async scheduling in rlhf_async_new_apis

合并时间：2026-05-08 19:58

原文链接：http://prhub.com.cn/vllm-project/vllm/pull/42042

执行摘要

- 一句话：RLHF 示例禁用异步调度以规避 Bug
- 推荐动作：该 PR 适合快速合入以修复 CI 稳定性问题，技术洞察价值有限。建议关注关联 Issue #42043 的根本修复，届时移除该工作区。

功能与动机

RayExecutorV2 成为默认后端后，CI 中 examples/rl/rlhf_async_new_apis.py 在 2 GPU H100 测试中持续失败。根本原因是 AsyncScheduler 在 pause_generation(mode="keep") 缓存重置后丢弃了第一个 post-resume token，使得训练后权重同步验证阶段的确定性比对无法通过。PR body 明确指出该工作区需要等待 #42043 的修复。

实现拆解

1. 定位入口：修改 examples/rl/rlhf_async_new_apis.py 中两个 llm_kwargs 字典的构建位置。
2. 首次添加：在 llm_kwargs（第 222 行）中增加 async_scheduling=False，并附上 TODO 注释，引用修复 Issue #42043，强调两个实例必须一致。
3. 二次添加：根据 Code Review 反馈，在 llm_v2_kwargs（第 363 行）中增加相同的 async_scheduling=False 和 TODO 注释，确保两个 LLM 实例配置对称，避免后续维护陷阱。
4. 无其他变更：仅添加 6 行代码（含注释），无测试、配置或部署文件改动。

关键文件：

- examples/rl/rlhf_async_new_apis.py（模块 RLHF 示例；类别 source；类型 entrypoint）：唯一的变更文件，是 RLHF 异步 API 的 CI 示例入口脚本。PR 在此文件中为两个 LLM 实例添加 async_scheduling=False 以规避 AsyncScheduler 的 token 丢失 Bug。

关键符号：未识别

关键源码片段

examples/rl/rlhf_async_new_apis.py

唯一的变更文件，是 RLHF 异步 API 的 CI 示例入口脚本。PR 在此文件中为两个 LLM 实例添加 async_scheduling=False 以规避 AsyncScheduler 的 token 丢失 Bug。

```
# 第一个 LLM 实例（V1）的配置参数字典
llm_kwargs = dict(
    model=MODEL_NAME_V1,
    enforce_eager=True,
    max_model_len=8192,
    distributed_executor_backend="ray",
    attention_backend=ATTN_BACKEND,
    gpu_memory_utilization=0.75,
    weight_transfer_config=WeightTransferConfig(backend="nccl"),
    # 临时禁用异步调度，直到 #42043 被修复。
    # 两个 LLM 实例必须保持一致的配置。
    async_scheduling=False,
)
llm_kwargs.update(rocm_determinism_kwargs)

# ...（中间代码省略）...

# 第二个 LLM 实例（V2）的配置参数字典
llm_v2_kwargs = dict(
    model=MODEL_NAME_V2,
    enforce_eager=True,
    max_model_len=8192,
    gpu_memory_utilization=0.75,
    distributed_executor_backend="ray",
    attention_backend=ATTN_BACKEND,
    # 临时禁用异步调度，直到 #42043 被修复。
    # 两个 LLM 实例必须保持一致的配置。
    async_scheduling=False,
)
llm_v2_kwargs.update(rocm_determinism_kwargs)
```

评论区精华

Gemini Code Assist Bot 在 Review 中提出两个实例需要对称的 TODO 注释，确保后续修复时统一跟踪。作者采纳并补充了第二个实例的注释。NickLucche批准了该PR。无其他争议讨论。

- 为第二个 LLM 实例补充 TODO 注释 (design): 作者接受了建议，在第二个实例中添加了相同的注释。

风险与影响

- 风险：低风险。变更仅涉及示例脚本中的配置参数，不改变核心引擎逻辑。禁用 async_scheduling 可能会轻微影响异步场景下的吞吐量，但 RLHF 示例主要用于验证权重同步的正确性，而非性能基准。后续需同步跟进 #42043 修复以重新启用异步调度。
- 影响：影响范围局限于 examples/rl/rlhf_async_new_apis.py 这一个示例文件。对用户而言，RLHF 示例现在能稳定通过 CI 验证阶段；对系统无影响；对团队降低了 CI 误报率。影响程度低。
- 风险标记：临时工作区，需后续跟进

关联脉络

- PR #41421 [Core] Make RayExecutorV2 the default executor backend: 引入 RayExecutorV2 为默认后端，直接导致 AsyncScheduler 行为变化，触发本 PR 需要规避的 Bug。
- PR #42043：该 Issue 将包含 AsyncScheduler 的根本修复，届时需要移除本 PR 添加的临时工作区。