

PR #47173 完整报告

vllm-project/vllm

[Frontend] Add /abort_requests to the RLHF dev API router

合并时间: 2026-07-12 14:21

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47173>

执行摘要

- 一句话: 为 RLHF dev API 路由添加 /abort_requests 端点
- 推荐动作: 值得精读, 特别是跨语言实现相同语义的设计 (Python 直接收集内部 ID, Rust 通过空向量表示中止所有)。注意 Rust 端跟踪时机窗口问题, 未来需关注是否引入锁或调整注册时机。

功能与动机

RL rollout 框架需要在步骤边界丢弃过采样 / 长尾生成, 同时保留部分输出。现有的 /pause?mode=abort 会暂停调度器需要 /resume, 使用不便。disagg 路由器已有等效 /abort_requests, 现在为 RLHF 开发路由器添加相同能力。

实现拆解

1. Python API 路由层: 在 vllm/entrypoints/serve/dev/rlhf/api_router.py 中添加 POST /abort_requests 异步处理函数。解析请求体, 若 request_ids 存在则直接调用 engine.abort(request_ids); 若缺失则从 AsyncLLM.output_processor 收集所有内部请求 ID (包括父请求 ID), 并调用 engine.abort(request_ids, internal=True) 以中止所有请求。同时处理 JSONDecodeError 返回 400。
2. Rust 前端路由层: 在 rust/src/server/src/routes/abort_requests.rs 中将 request_ids 从必填改为可选, 使用 unwrap_or_default() 替代 ok_or_else 错误返回, 空 body 时传递空向量给后端。
3. Rust LLM 内核: 在 rust/src/llm/src/lib.rs 中扩展 Llm::abort 方法: 当 external_ids 为空时调用 self.inflight.all_internal_ids() 收集所有跟踪的内部 ID, 否则使用原 resolve 逻辑。
4. 跟踪机制: 在 rust/src/llm/src/inflight.rs 中新增 all_internal_ids 方法, 从锁保护的 HashMap 中收集所有内部 ID。
5. 测试与文档: 在 rust/src/server/src/routes/tests.rs 中将空 body 预期从 400 改为 200 并重命名测试函数; 同步更新三份文档文件添加端点说明。

关键文件:

- vllm/entrypoints/serve/dev/rlhf/api_router.py (模块 API 路由; 类别 source; 类型 endpoint; 符号 abort_requests): 核心入口, 添加 POST /abort_requests 端点, 处理指定或全部请求中止, 并包含关键修复 (internal=True、parent IDs、JSON 拒绝)。

- rust/src/server/src/routes/abort_requests.rs (模块 Rust 路由; 类别 source; 类型 endpoint) : Rust 前端路由, 修改 request_ids 从必填变为可选, 实现空 body 转发。
- rust/src/llm/src/lib.rs (模块 Rust 内核; 类别 source; 类型 core-logic) : Rust LLM 核心, 扩展 abort 方法以支持空 external_ids 时中止所有请求。
- rust/src/llm/src/inflight.rs (模块 请求跟踪; 类别 source; 类型 core-logic) : 新增 all_internal_ids 方法, 支持获取所有在途请求 ID。
- rust/src/server/src/routes/tests.rs (模块 测试套件; 类别 source; 类型 test; 符号 abort_requests_route_rejects_missing_request_ids, abort_requests_route_aborts_all_when_request_ids_missing) : 更新测试用例, 反映空 body 行为从 400 变为 200。
- docs/serving/online_serving/README.md (模块 文档; 类别 docs; 类型 documentation) : 新增端点文档说明。
- docs/training/async_rl.md (模块 文档; 类别 docs; 类型 documentation) : 同步更新文档。
- docs/usage/security.md (模块 文档; 类别 docs; 类型 documentation) : 同步更新文档。

关键符号: abort_requests, abort_requests (Rust route), abort (Llm), all_internal_ids (InflightRequests), abort_requests_route_rejects_missing_request_ids (test), abort_requests_route_aborts_all_when_request_ids_missing (test)

关键源码片段

[vllm/entrypoints/serve/dev/rlhf/api_router.py](#)

核心入口, 添加 POST /abort_requests 端点, 处理指定或全部请求中止, 并包含关键修复 (internal=True、parent IDs、JSON 拒绝)。

```
@router.post("/abort_requests")
async def abort_requests(raw_request: Request) -> JSONResponse:
    """Abort in-flight requests without pausing the scheduler.

    Empty/missing `request_ids` aborts all in-flight requests.
    """
    engine = engine_client(raw_request)

    # Parse JSON body; reject malformed JSON explicitly
    try:
        body = await raw_request.json()
    except json.JSONDecodeError as e:
        raise HTTPException(status_code=400, detail="Invalid JSON format") from e

    request_ids = body.get("request_ids")

    try:
        if request_ids:
            # User-supplied external IDs
            await engine.abort(request_ids)
```

```

else:
    # Dev RL server uses AsyncLLM; gather all internal IDs
    from vllm.v1.engine.async_llm import AsyncLLM
    assert isinstance(engine, AsyncLLM)
    op = engine.output_processor
    # Include both child (request_states) and parent (parallel-sampling) IDs
    request_ids = [
        *op.request_states.keys(),
        *op.parent_requests.keys(),
    ]
    # Internal flag is required because these are internal suffixed IDs
    await engine.abort(request_ids, internal=True)
    return JSONResponse(
        content={"status": "aborted", "aborted": len(request_ids)},
        status_code=HTTPStatus.OK.value,
    )
except Exception as err: # pragma: no cover - defensive
    logger.exception("Failed to abort requests")
    return JSONResponse(
        content={"error": f"Failed to abort requests: {err}"},
        status_code=HTTPStatus.INTERNAL_SERVER_ERROR.value,
    )

```

rust/src/server/src/routes/abort_requests.rs

Rust 前端路由，修改 request_ids 从必填变为可选，实现空 body 转发。

```

use std::sync::Arc;

use axum::Json;
use axum::extract::State;
use axum::extract::rejection::JsonRejection;
use axum::http::StatusCode;
use serde::Deserialize;

use crate::error::ApiError;
use crate::state::AppState;
use crate::utils::utility_call_error;

#[derive(Debug, Deserialize)]
pub(crate) struct AbortRequestsRequest {
    // `request_ids` is now optional; missing/unwrapped defaults to empty vec
    request_ids: Option<Vec<String>>,
}

pub async fn abort_requests(
    State(state): State<Arc<AppState>>,
    body: Result<Json<AbortRequestsRequest>, JsonRejection>,
) -> Result<StatusCode, ApiError> {
    let Json(body) = body.map_err(|error| ApiError::json_parse_error(error.body_text()))?;

```

```

// Empty/missing `request_ids` aborts all in-flight requests.
let request_ids = body.request_ids.unwrap_or_default();

state
    .chat
    .abort(&request_ids)
    .await
    .map_err(|error| utility_call_error("abort_requests", error))?;

Ok(StatusCode::OK)
}

```

rust/src/llm/src/lib.rs

Rust LLM 核心，扩展 abort 方法以支持空 external_ids 时中止所有请求。

```

/// Abort in-flight requests by their external (user-supplied) request ids.
///
/// External ids are resolved to the internal engine ids actually known to
/// engine-core (one external id may map to several internal ids). Unknown
/// or already-finished ids resolve to nothing and are a safe no-op. The
/// tracking entries themselves are removed when the corresponding output
/// streams are dropped, not here.
pub async fn abort(&self, external_ids: &[String]) -> Result<()> {
    // Empty `external_ids` means abort every in-flight request.
    let internal_ids = if external_ids.is_empty() {
        self.inflight.all_internal_ids()
    } else {
        self.inflight.resolve(external_ids)
    };
    if internal_ids.is_empty() {
        return Ok(());
    }
    self.client.abort(&internal_ids).await?;
    Ok()
}

```

评论区精华

- 内部 ID 标记问题：Codex 评论指出空 body 路径需要设置 internal=True 否则 abort 无效，作者后续 commit 修复。
- Malformed JSON 处理：Codex 建议区分空 body 与 malformed JSON 避免误终止所有请求，作者通过捕获 JSONDecodeError 返回 400 修复。
- 并行采样父 ID 泄漏：Codex 指出中止所有时只收集子请求 ID 导致父条目残留，作者通过添加 parent_requests.keys() 修复。
- Rust 端跟踪时机：Codex 提出 abort-all 可能遗漏尚未跟踪的请求（因为 Llm::generate() 在 await 后才添加跟踪），未在 PR 中解决。
- 计数不准确：Codex 指出返回的 **aborted** 计数可能包含未实际中止的 ID，未修复。

- 空 body 时未使用 `internal=True` 导致 abort 无效 (correctness): 作者在后续 commit 中添加了 `internal=True`。
- Malformed JSON 被当作空 body 可能误终止所有请求 (correctness): 作者通过捕获 `JSONDecodeError` 并返回 400 修复。
- 并行采样父 ID 泄漏 (correctness): 作者通过添加 `parent_requests.keys()` 修复。
- Rust 端 abort-all 遗漏尚未跟踪的请求 (correctness): 未在 PR 中修复, 可能认为影响有限或后续处理。

风险与影响

• 风险:

1. 空 body 语义可能误终止所有请求, 尤其在 Rust 端跟踪时机窗口内请求未完全注册时。
2. 并行采样父 ID 泄漏问题已修复, 但返回的计数仍可能不准确。
3. 依赖 AsyncLLM 内部结构 (`output_processor`、`parent_requests`), 未来重构可能引发兼容性问题。
4. Rust 端 `all_internal_ids` 仅覆盖已注册请求, `generate()` 中 `client.call` 之前发生的 abort-all 会遗漏。

• 影响:

- 用户: RL 训练框架开发者获得更精细的请求控制, 无需暂停 / 恢复调度器, 简化 rollout 流程。
- 系统: 新增一个端点, 对整体性能无影响。
- 团队: 需要维护 Python 和 Rust 两个实现, 但逻辑一致, 降低长期维护成本。
- 风险标记: 空 body 误终止, 并行父 ID 泄漏 (已修复), Rust 跟踪窗口遗漏, aborted 计数不准确

关联脉络

- PR #46725 Runtime Draft Weight Update for Speculative Decoding: 在同一个 RLHF 开发路由器上添加了 weight transfer 相关端点, 本 PR 是同一系列的延续。