

PR #46833 完整报告

vllm-project/vllm

[Rust Frontend] Start current wave for a stale DP FirstRequest

合并时间: 2026-06-30 13:13

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46833>

执行摘要

本 PR 修复了 Rust 进程内 DP 协调器中的一个竞态条件: 当 `FirstRequest` 入队后引擎提前完成 wave 导致 `current_wave` 前进时, 旧的 `FirstRequest` 错误地回退 wave。通过引入 `start_wave_for_first_request` 方法, 确保广播当前 wave 并在请求过时唤醒所有引擎 (`exclude = None`), 行为与 Python 协调器一致。

功能与动机

"In the in-process DP coordinator, `notify_first_request` enqueues `FirstRequest{wave: W}` while engines are paused, but the runner broadcasts `START_DP_WAVE` later. If engines report `WaveComplete(W)` in that gap, `current_wave` advances to `W+1`. The stale `FirstRequest{wave: W}` was then applied unconditionally, rewinding `current_wave` back to `W` and broadcasting a superseded wave."

需要确保 Rust 实现与 Python 协调器的行为一致, 即: 从不回退 wave, 广播当前 wave, 并在请求 wave 过时排除 `None` (唤醒所有引擎)。

实现拆解

1. 修改 `StartDpWaveMessage` 和 `broadcast_start_wave` (`inproc.rs`): 将 `exclude_engine_index` 字段类型从 `u32` 改为 `Option<u32>`, 以支持 `None` 值 (唤醒所有引擎)。更新 `broadcast_start_wave` 签名和实现。
2. 新增 `start_wave_for_first_request` 方法 (`handle.rs`): 在 `CoordinatorStateSnapshot` 上实现新方法, 接收 `request_wave` 和 `target_engine_index`。将 `engines_running` 置为 `true`, 然后根据 `request_wave >= current_wave` 决定 `exclude`: 成立时排除目标引擎, 否则为 `None`。始终返回 `self.current_wave`, 确保不回退。
3. 重构 `handle_command` 的 `FirstRequest` 分支 (`inproc.rs`): 不再直接设置 `state.lock().current_wave = wave`, 而是调用 `state.start_wave_for_first_request(wave, target_engine_index)` 获取当前 wave 和 `exclude`, 然后以此广播。
4. 更新另一处 `broadcast_start_wave` 调用: 引擎通知过时 wave 时, 改为传递 `Some(engine_index)`。
5. 添加单元测试: 覆盖正常路径 (请求 wave 等于当前 wave, 排除目标引擎) 和过时路径 (请求 wave 小于当前 wave, `exclude` 为 `None`)。

`rust/src/engine-core-client/src/coordinator/inproc.rs`

核心变更文件：修改 broadcast_start_wave 参数类型，重构 handle_command 中 FirstRequest 分支逻辑，并新增单元测试。

```
// rust/src/engine-core-client/src/coordinator/inproc.rs ( 关键变更部分 )

/// 广播 START_DP_WAVE 消息给所有引擎。
/// exclude_engine_index 为 None 时唤醒所有引擎（用于过时请求 wave）。
async fn broadcast_start_wave(
    &mut self,
    wave: u32,
    exclude_engine_index: Option<u32>, // 从 u32 改为 Option<u32>
) -> Result<()> {
    let payload = encode_msgpack(&StartDpWaveMessage {
        wave,
        exclude_engine_index,
    })?;
    self.coordinator_input
        .send(
            ZmqMessage::try_from(vec![
                EngineCoreRequestType::StartDpWave.to_frame(),
                payload.into(),
            ])
        )
        .expect("coordinator START_DP_WAVE message must contain two frames"),
    )
    .await?;
    Ok(())
}

// handle_command 中 FirstRequest 分支，不再直接设置 current_wave,
// 而是委托给 start_wave_for_first_request 处理过时判断。
CoordinatorCommand::FirstRequest {
    target_engine_id,
    wave,
} => {
    let target_engine_index = target_engine_id.engine_index().ok_or_else(|| {
        Error::UnsupportedCoordinatorEngineId {
            engine_id: target_engine_id.to_vec(),
        }
    })?;
    // 获取当前 wave 和 exclude 值，注意这里不改变 current_wave
    let (current_wave, exclude) = {
        let mut state = self.state.lock();
        state.start_wave_for_first_request(wave, target_engine_index)
    };
    debug!(
        current_wave,
        request_wave = wave,
        ?exclude,
        "starting DP wave after first request while engines were paused"
    );
}
```

```

);
// 广播当前 wave, exclude 为 None 时唤醒所有引擎
self.broadcast_start_wave(current_wave, exclude).await?;
}

// 单元测试: 过时请求 broadcast 全部引擎
#[test]
fn stale_first_request_starts_current_wave_for_all_engines() {
    let mut state = CoordinatorStateSnapshot {
        current_wave: 4,
        engines_running: false,
    };
    // 请求 wave 3 小于 current_wave 4, 说明 wave 已过时
    let (wave, exclude) = state.start_wave_for_first_request(3, 2);
    assert_eq!(wave, 4); // 广播当前 wave, 不回退
    assert_eq!(exclude, None); // 唤醒所有引擎
    assert!(state.engines_running);
    assert_eq!(state.current_wave, 4); // current_wave 保持不变
}

```

rust/src/engine-core-client/src/coordinator/handle.rs

新增 start_wave_for_first_request 方法, 封装过时 wave 判断逻辑; 修改 exclude 字段类型为 Option。

// rust/src/engine-core-client/src/coordinator/handle.rs (新增方法)

```

impl CoordinatorStateSnapshot {
    /// 为 FirstRequest 启动 wave, 返回要广播的 wave 和要排除的引擎索引。
    /// 如果 request_wave 小于 current_wave (过时), 则 exclude 为 None (唤醒所有引擎),
    /// 且绝不回退 current_wave。
    pub(crate) fn start_wave_for_first_request(
        &mut self,
        request_wave: u32,
        target_engine_index: u32,
    ) -> (u32, Option<u32>) {
        self.engines_running = true;
        // 当 request_wave >= current_wave 时, 说明请求 wave 是当前的,
        // 排除目标引擎 (它已经接收过请求); 否则 (过时) None 唤醒所有引擎。
        let exclude = (request_wave >= self.current_wave).then_some(target_engine_index);
        (self.current_wave, exclude) // 始终返回 current_wave, 不回退
    }
}

```

// StartDpWaveMessage 结构体中的 exclude 字段类型改变

```

struct StartDpWaveMessage {
    wave: u32,
    /// Engine index that already received the triggering request and so does not
    /// need an extra wakeup. `None` wakes every engine (used when the triggering
    /// request was for a stale wave).
    exclude_engine_index: Option<u32>, // 从 u32 改为 Option<u32>
}

```

```
}
```

评论区精华

Review 由 BugenZhao 批准，评论为 "LGTM. Thanks!", 无其他讨论或争议。

风险与影响

- 风险：较低。变更仅影响 Rust 进程内 DP 协调器，修复了一个明确的竞态条件 bug。测试覆盖了正常和过时路径。
- 影响：修复了 DP 数据并行场景下 wave 管理的一个潜在正确性问题，使 Rust 实现与 Python 协调器行为一致。不影响 Python 协调器或其他系统模块。

关联脉络

本 PR 是 Rust 前端系列工作的一部分（如 PR #45890），旨在逐步用 Rust 重写 vLLM 的前端组件。本次修复对齐了 Rust 协调器与 Python 协调器的行为，为后续功能演进打下基础。