

PR #46348 完整报告

vllm-project/vllm

[Rust Frontend] Align Rust allowed_token_ids validation with Python

合并时间: 2026-06-23 16:32

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46348>

执行摘要

此 PR 修复 Rust OpenAI 前端与 Python 端在 `allowed_token_ids` 参数上的行为不一致: 当显式传入空列表 `[]` 时, Python 端会拒绝并报错, 而 Rust 端之前仅检查 out-of-vocab 情况, 导致空列表被接受。现在通过在 Rust 请求验证路径中添加 `EmptyAllowedTokenIds` 错误变体, 两端行为完全对齐, 返回相同的 400 `invalid_request_error`。

功能与动机

Python 端的 `SamplingParams` 会检查 `allowed_token_ids is not None and empty!` 并拒绝空列表, 但 Rust 前端仅校验 token ID 是否超出词表, 忽略空列表场景。为了消除跨前端的行为歧义, PR 为其补上了这一校验, 确保客户端无论使用 Python 还是 Rust 的前端入口, 都能收到一致的报错提示。

实现拆解

1. 错误类型重构 (`rust/src/text/src/lower/token_ids.rs`): 将原有的 `OutOfVocabError` 结构体重构成 `TokenIdsError` 枚举, 新增 `EmptyAllowedTokenIds` 变体, 并把原结构体作为 `OutOfVocab` 枚举变体内联, 保持错误类型层次单一。
2. 核心验证函数增强 (`rust/src/text/src/lower/token_ids.rs`): 在 `validate_vocab_range` 中, 当 `allowed_token_ids` 存在且为空时, 立即返回 `EmptyAllowedTokenIds` 错误, 不再继续校验词表范围。
3. 测试用例更新 (`rust/src/text/src/lower.rs`): 将原有所有匹配 `OutOfVocabError` 的断言替换为匹配 `TokenIdsError::OutOfVocab`, 并新增 `lower_sampling_params_rejects_empty_allowed_token_ids` 单元测试, 验证空列表被正确拒绝。
4. 错误映射与导出:
 - `rust/src/text/src/error.rs` & `rust/src/text/src/lib.rs`: 替换 `pub use` 和 `Error` 变体, 将 `OutOfVocabError` 改为 `TokenIdsError`。
 - `rust/src/server/src/error.rs`: 更新 `is_request_validation_error` 函数匹配的变体, 并新增 `empty_allowed_token_ids_maps_to_invalid_request` 单元测试, 确保新错误映射到 HTTP 400。
5. 集成测试覆盖 (`rust/src/server/src/routes/tests.rs`): 新增两个 e2e 测试, 分别对 `/v1/completions` 和 `/v1/chat/completions` 传入空 `allowed_token_ids`, 验证返回 400 状态码及正确的错误消息。

`rust/src/text/src/lower/token_ids.rs`

核心验证逻辑变更：引入 TokenIdsError 枚举并添加空列表检查。

```
// 文件 : rust/src/text/src/lower/token_ids.rs
// 引入的 TokenIdsError 枚举，统一 token ID 验证错误
#[derive(Debug, Error)]
pub enum TokenIdsError {
    // 新增: allowed_token_ids 为空时使用此变体
    #[error("`allowed_token_ids` should not be empty")]
    EmptyAllowedTokenIds,
    // 原有 out-of-vocab 错误内联为枚举变体
    #[error(
        "token_id(s) {token_ids:?} in {parameter} contain out-of-vocab token ids. \
        Vocabulary size: {vocab_size}"
    )]
    OutOfVocab {
        parameter: &'static str,
        token_ids: Vec<u32>,
        vocab_size: usize,
    },
}

// validate_vocab_range 函数：校验采样参数中的 token ID 范围
pub(crate) fn validate_vocab_range(
    params: &EngineCoreSamplingParams,
    limits: &SamplingLimits,
) -> Result<(), TokenIdsError> {
    // 校验 stop_token_ids
    validate_param("stop_token_ids", params.stop_token_ids.iter().copied(), limits.model_vocab_size)?;

    // 校验 allowed_token_ids: 先检查是否为空，再校验范围
    if let Some(token_ids) = params.allowed_token_ids.as_deref() {
        // 新增空列表检查：Python 端同样拒绝此情况
        if token_ids.is_empty() {
            return Err(TokenIdsError::EmptyAllowedTokenIds);
        }
        validate_param("allowed_token_ids", token_ids.iter().copied(), limits.tokenizer_vocab_size)?;
    }

    // 其余 logit_bias、logprob_token_ids、bad_words_token_ids 校验保持不变
    // ...
    Ok(())
}
```

[rust/src/server/src/error.rs](#)

更新错误映射和测试，确保新错误类型映射到 HTTP 400。

```
// 文件 : rust/src/server/src/error.rs
// 判断是否为请求验证错误的函数
fn is_request_validation_error(error: &vllm_text::Error) -> bool {
```

```

matches!(
    error,
    vllm_text::Error::PromptTooLong { .. }
    | vllm_text::Error::EmptyPromptTokenIds { .. }
    | vllm_text::Error::Logprobs(_)
    // 将旧的 OutOfVocab 变体替换为新的 TokenIds 变体
    | vllm_text::Error::TokenIds(_)
    | vllm_text::Error::InvalidThinkingTokenBudget
    | vllm_text::Error::Llm(vllm_llm::Error::EmptyPromptTokenIds { .. })
)
}

// 新增测试: 验证空 allowed_token_ids 映射为 400 invalid_request_error
#[test]
fn empty_allowed_token_ids_maps_to_invalid_request() {
    let error = vllm_text::Error::TokenIds(vllm_text::TokenIdsError::EmptyAllowedTokenIds);
    let api_error = text_submit_error("failed to submit completion request", error);
    assert_eq!(api_error.status_code(), StatusCode::BAD_REQUEST);
    let response = api_error.to_error_response();
    assert_eq!(response.error.error_type, "invalid_request_error");
    assert!(response.error.message.contains("allowed_token_ids"));
}

```

评论区精华

- BugenZhao建议将独立的 OutOfVocabError 结构体内联为 TokenIdsError 枚举变体，避免 text::Error 中保留两个独立变体。此重构被作者采纳，最终提交中 OutOfVocabError 成为 TokenIdsError::OutOfVocab。
- BugenZhao还建议调整错误消息格式，将 "allowed_token_ids is not None and empty!" 改为 "allowed_token_ids should not be empty"，使信息更简洁且与项目风格一致。最终提交已更新。

风险与影响

- 向后兼容性：之前能通过的 allowed_token_ids: [] 请求现在会被拒绝。这属于修复行为不一致，不算是兼容性 break，但客户端如果存在此类调用需要更新。
- 测试覆盖：单元测试和集成测试均已补充，风险很低。
- 影响范围：仅影响请求验证早期阶段，不涉及引擎核心或性能路径。

关联脉络

此 PR 是 Rust 前端参数验证体系持续完善的一部分。与之关联的 [#PR 46359](#) 同样修改了 `lower.rs` 和 `error.rs`，修正了 `--reasoning-parser` 的语义。两者共同提升了 Rust 前端与 Python 前端的验证一致性。