

PR #47707 完整报告

vllm-project/vllm

[Bugfix][Rust Frontend] Detokenizer: avoid leaking prompt on zero-generated-token completions

合并时间: 2026-07-16 17:11

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47707>

执行摘要

本 PR 修复了 Rust 前端分词器 (`DecodeStream`) 中一个边界条件 bug: 当模型输出的唯一 token 是 EOS 并被引擎抑制时, `flush()` 会将整个 prompt 文本泄漏到输出结果中。修复通过检查 `prefix_seeded` 标志, 确保只有在实际推送过 token 后才执行解码, 否则返回空文本, 与 Python V1 前端行为一致。

功能与动机

当请求以零生成 token 结束时——例如模型首 token 即为 EOS, 引擎将其抑制——`flush()` 在 `push_token()` 从未被调用的情况下被触发。此时 `DecodeStream` 的 `ids` 中仍持有全部 prompt token id (作为解码的左侧上下文), 而 `prefix` 为空, 因为 `seed_prefix()` 仅在 `push_token()` 中调用。原代码在 `flush()` 中无条件解码 `ids`, 导致整个 prompt 被追加到 `cumulative_output`, 最终返回给用户。这与 Python V1 路径中 `BaseIncrementalDetokenizer.update()` 在 `new_token_ids` 为空时直接返回的行为不一致。

实现拆解

1. 问题定位: 分析 `DecodeStream::flush()` 原实现: `if !self.ids.is_empty()` 时直接解码, 但 `ids` 在零 token 场景下只包含 prompt, `prefix_len` 为 0, 导致 prompt 全文被输出。
2. 修复核心: 将条件改为 `if self.prefix_seeded && !self.ids.is_empty()`。 `prefix_seeded` 仅在 `push_token()` 中设为 `true`, 因此无 token 推送时不会进入解码分支。同时将 `ids`、`prefix`、`prefix_index` 的清除操作移到条件块之外, 确保状态始终重置。
3. 测试覆盖: 新增两个回归测试:
 - `flush_without_push_token_does_not_leak_prompt`: 7001 token 的 prompt, 验证返回空文本。
 - `flush_without_push_token_does_not_leak_undecodable_prompt_tail`: 不完整 UTF-8 序列 `[0xe4, 0xbd]`, 验证即使 `seed_prefix()` 无法建立有效 prefix, 也不会泄漏。

rust/src/tokenizer/src/incremental.rs

包含 `DecodeStream::flush()` 方法的核心修复和两个新增的回归测试。

```
fn flush(&mut self, truncate_output_to: Option<usize>) -> Result<(Option<String>, String)> {  
    // 如果 prefix 从未被种子化 (即从未调用 push_token) ,  
    // 则 ids 中只包含 prompt context —— 解码它会重复输出 prompt 文本。  
    // 仅当 prefix_seeded 且 ids 非空时才执行解码;  
    // 否则跳过解码, 直接清理状态, 返回空文本。
```

```

if self.prefix_seeded && !self.ids.is_empty() {
    let string = self.tokenizer.decode(&self.ids, self.skip_special_tokens)?;
    let prefix_len = self.prefix.len();
    // 确保在 UTF-8 字符边界处切割。
    self.cumulative_output
        .push_str(&string[string.floor_char_boundary(prefix_len)..]);
}
self.ids.clear();
self.prefix.clear();
self.prefix_index = 0;
self.prefix_seeded = true;
if let Some(truncate_output_to) = truncate_output_to {
    self.cumulative_output.truncate(truncate_output_to);
}
let last_chunk = (self.output_index < self.cumulative_output.len())
    .then(|| self.cumulative_output[self.output_index..].to_string());
self.output_index = 0;
Ok((last_chunk, take(&mut self.cumulative_output)))
}

// 回归测试: 验证零生成 token 时 flush 不泄漏 prompt
#[test]
fn flush_without_push_token_does_not_leak_prompt() {
    let backend = Utf8Backend;
    let prompt: Vec<u32> = b"The quick brown fox jumps over the lazy dog. "
        .iter()
        .cycle()
        .take(7001)
        .map(|&bl b as u32| b)
        .collect();
    let mut decoder = backend.create_decode_stream(&prompt, false, 0);
    let (last_chunk, full_text) = decoder.flush(None).unwrap();
    assert_eq!(last_chunk, None);
    assert_eq!(full_text, "");
}

// 回归测试: 即使 prompt 尾部是不可解码的不完整 UTF-8, 也不泄漏
#[test]
fn flush_without_push_token_does_not_leak_undecodable_prompt_tail() {
    let backend = Utf8Backend;
    let prompt = vec![0xe4, 0xbd];
    let mut decoder = backend.create_decode_stream(&prompt, false, 0);
    let (last_chunk, full_text) = decoder.flush(None).unwrap();
    assert_eq!(last_chunk, None);
    assert_eq!(full_text, "");
}

```

评论区精华

BugenZhao: “Do we really need to seed the prefix here anyway? Can we simply do decode here only when `if self.prefix_seeded && !self.ids.is_empty()`?”

xiaguan: “Thanks for pointing this out — you're right. If `prefix_seeded` is false at flush time, `push_token()` was never called and `ids` only holds prompt context, so seeding a prefix that gets discarded right after is wasted work.”

这一简洁的设计建议将修复从「先种子化再跳过」简化为「直接检查标志」，避免了不必要的操作，体现了良好的代码审视。

风险与影响

- 风险：低。修复仅改变 `flush()` 中解码的条件，对正常（有生成 token）的流程无影响。`prefix_seeded` 在 `push_token()` 后为 `true`，逻辑不变。
- 影响：仅限于 Rust 前端分词器在零生成 token 请求下的行为，消除 prompt 泄漏。与 Python V1 前端行为保持一致性。

关联脉络

此 PR 是 Rust 前端分词器维护的一部分，近期无直接关联的 PR（无重复函数或模块变更）。它独立修复了一个边界条件，确保了 Rust 前端的鲁棒性。