

PR #49113 完整报告

vllm-project/vllm

[Bugfix][Rust Frontend] Handle zero-column logprobs payloads without panicking

合并时间: 2026-07-21 12:30

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/49113>

执行摘要

本 PR 修复了 Rust `engine-core-client` 中当 logprobs 载荷为零行或零列时 `slice::chunks` 因 chunk size 为零而 panic 的问题。变更在解码器中添加了两个守卫分支：零行时返回空 `Logprobs`，零列时返回结构化错误。新增两个单元测试覆盖这些异常路径。该修复对 Python runner 用户无影响，但增强了引擎核心协议边界的健壮性。

功能与动机

`engine-core` 协议可能携带零个评分位置的 logprobs 载荷，例如 `[0,0]` 或 `[0,k+1]` 张量形状。解码器直接将列数传入 `slice::chunks`，当块大小为零时会无条件 panic。虽然 Python runner 不会发送此类形状，但 `engine-core` 协议是公开边界，panic 是错误的失败模式。该问题在审查 `openinfer` 相关 PR 时被发现。

实现拆解

- 在 `WireLogprobs::decode` 中添加前置守卫 (`rust/src/engine-core-client/src/protocol/logprobs.rs`) :
 - 在形状校验后、chunks 循环前插入两个守卫。
 - 若 `token_ids.rows == 0`，直接返回空的 `Logprobs`。
 - 若 `token_ids.cols == 0` 且 `rows > 0`，通过 `bail_ext_value_decode!` 返回 `ExtValueDecode` 错误。
- 新增单元测试 (`rust/src/engine-core-client/src/protocol/logprobs/tests.rs`) :
 - `decodes_zero_row_logprobs_as_empty`: 验证 `[0,0]` 和 `[0,3]` 形状均解码为空。
 - `rejects_zero_column_logprobs_with_rows`: 验证 `[2,0]` 形状返回错误而非 panic。

`rust/src/engine-core-client/src/protocol/logprobs.rs`

核心修复逻辑所在：在 `decode` 方法中添加了零行和零列的前置检查，避免 panic。

```
// rust/src/engine-core-client/src/protocol/logprobs.rs
```

```
// 在形状校验完成后，chunks 循环之前插入以下守卫分支
```

```
// Empty position lists may be encoded as either [0, 0] or [0, k + 1].
```

```
// 零行载荷：直接返回空 positions，避免后续 `slice::chunks` 因 chunk size 为零而 panic
```

```
if token_ids.rows == 0 {  
    return Ok(Logprobs {
```

```

        positions: Vec::new(),
    });
}

// 零列但非零行的载荷：不可能有意义，报出结构化错误而非 panic
if token_ids.cols == 0 {
    bail_ext_value_decode!(
        "{field_prefix}: zero-column logprobs payload with {} rows",
        token_ids.rows
    );
}

```

rust/src/engine-core-client/src/protocol/logprobs/tests.rs

新增了两个单元测试，覆盖零行和零列两种异常场景。

```

// rust/src/engine-core-client/src/protocol/logprobs/tests.rs

#[test]
// 验证零行 logprobs 形状 [0,0] 和 [0,3] 均解码为空，不会 panic
fn decodes_zero_row_logprobs_as_empty() {
    for shape in [[0usize, 0], [0, 3]] {
        let frames = vec![Bytes::from(encode_value(&output_wire_with_custom_fields(
            None,
            Some(Value::Array(vec![
                ndarray_value("<i8", &shape, Value::Ext(3, Vec::new()))),
                ndarray_value("<f4", &shape, Value::Ext(3, Vec::new()))),
                ndarray_value("<i8", &[0], Value::Ext(3, Vec::new()))),
                Value::Nil,
            ])),
        ]));
        let decoded = decode_engine_core_outputs(&frames)
            .unwrap()
            .into_request_batch()
            .unwrap();
        let logprobs = decoded.outputs[0]
            .new_prompt_logprobs_tensors
            .clone()
            .unwrap()
            .into_direct()
            .unwrap();
        assert!(logprobs.is_empty());
    }
}

#[test]
// 验证零列但非零行的 payload 导致 ExtValueDecode 错误而非 panic
fn rejects_zero_column_logprobs_with_rows() {
    let ranks = Value::Ext(3, vec![1, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0]);
    let frames = vec![Bytes::from(encode_value(&output_wire_with_custom_fields(

```

```

        Some(Value::Array(vec![
            ndarray_value("<i8", &[2, 0], Value::Ext(3, Vec::new())),
            ndarray_value("<f4", &[2, 0], Value::Ext(3, Vec::new())),
            ndarray_value("<i8", &[2], ranks),
            Value::Nil,
        ])),
        None,
    )));

let error = decode_engine_core_outputs(&frames).unwrap_err();
let crate::error::Error::ExtValueDecode { message } = &error else {
    panic!("expected ExtValueDecode");
};
assert_eq!(
    message,
    "new_logprobs: zero-column logprobs payload with 2 rows"
);
}

```

评论区精华

- BugenZhao 询问上下文是否来自 [openinfer-project/openinfer#721](#)，作者 FeathBow 澄清是在审查 [openinfer-project/openinfer#722](#) 时发现的，并非直接关联。
- BugenZhao 以 LGTM 批准。

风险与影响

- 风险：低。变更为新增前置返回分支，不改变现有逻辑路径；测试覆盖了新增的两种异常情况。但缺少集成测试验证与其他引擎核心的兼容性。
- 影响：直接影响自定义 engine-core 实现的用户；对使用原始 Python runner 的用户无影响。

关联脉络

该 PR 与 [PR #48992](#) (Rust Frontend 引擎感知健康报告) 同属于 Rust engine-core-client 模块的改进，增强了协议层的健壮性。