

PR #47581 完整报告

vllm-project/vllm

[Rust Frontend] Avoid extra copies for multimodal tensors

合并时间: 2026-07-07 11:09

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47581>

Rust Frontend 多模态张量零拷贝优化

执行摘要

本 PR 消除了 Rust 前端在处理多模态请求时的两处不必要字节克隆：一是在 `lower_text_request` 中通过 `Option::take()` 移动 `mm_features`，二是在 `WireArrayData::RawView` 序列化时使用借字节的 `MsgpackExtRef` 替代 `Value::Ext(..., clone)`。变更保持线格式完全不变，不引入新依赖，对 engine 侧行为无影响。

功能与动机

多模态请求携带的 tensor 缓冲区（如图像 `pixel_values`）可能极大。PR body 指出此前 Rust 前端对每个多模态请求有两处不必要的分配和拷贝：

1. `lower_text_request` 克隆了 `request.mm_features`（一个包含大字节 buffer 的 `Vec<MmFeatureSpec>`）给 `GenerateRequest`；
2. `WireArrayData::RawView` 序列化时克隆了整个字节缓冲区用于构造 `Value::Ext`。

这些多余的拷贝增加了 per-request 的 CPU 负载和临时内存压力，对于大图像请求尤为明显。

实现拆解

1. `rust/src/text/src/lower.rs`: 移动 `mm_features` 所有权 - 函数签名改为 `mut request: TextRequest`； - `mm_features: request.mm_features.take()` 替代 `mm_features: request.mm_features.clone()`； - 迁移后 `text_request.mm_features` 为 `None`，与 Python 响应解码路径一致； - 补充单元测试 `lower_text_request_moves_multimodal_features_to_generate_request` 验证转移正确性。
2. `rust/src/engine-core-client/src/protocol/tensor.rs`: 零拷贝 MessagePack 扩展序列化 - 引入 `MsgpackExtRef<'a>` 结构体，通过 `_ExtStruct` 标记让 `rpm-serde` 将其编码为 MessagePack 扩展类型； - 引入 `ByteSlice<'a>` 作为 `&[u8]` 的 newtype，其 `Serialize` 实现调用 `serialize_bytes`，确保 `rpm-serde` 使用正确的字节编码路径（而非序列化）； - 修改 `WireArrayData::RawView` 分支：从 `Value::Ext(CUSTOM_TYPE_RAW_VIEW, bytes.clone())` 改为 `MsgpackExtRef((CUSTOM_TYPE_RAW_VIEW, ByteSlice(bytes)))`，消除克隆； - 补充单元测试 `raw_view_serializes_as_msgpack_ext` 验证序列化结果与旧路径完全一致。

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

核心序列化路径：新增 `MsgpackExtRef` 和 `ByteSlice` 实现零拷贝 MessagePack 扩展编码，修改 `WireArrayData::RawView` 序列化避免克隆。

```
/// MessagePack extension struct that serializes without copying bytes.
///
/// `rmp-serde`'s `_ExtStruct` path expects the second tuple element to use
/// `serialize_bytes()` to produce a bin/str value inside the ext. By wrapping
/// `&[u8]` in `ByteSlice` (which delegates to `serialize_bytes`), we
/// avoid both a `serde_bytes` dependency and cloning the entire byte buffer.
#[derive(Serialize)]
#[serde(rename = "_ExtStruct")]
struct MsgpackExtRef<'a>((i8, ByteSlice<'a>));

/// Newtype over `&[u8]` to force `serde`'s bytes serialization path.
struct ByteSlice<'a>(&'a [u8]);

impl Serialize for ByteSlice<'_> {
    fn serialize<S>(&self, serializer: S) -> std::result::Result<S::Ok, S::Error>
    where
        S: Serializer,
    {
        // `serialize_bytes` is what `rmp-serde`'s `_ExtStruct` expects for the
        // binary payload; a plain `&[u8]` would serialize as a sequence.
        serializer.serialize_bytes(self.0)
    }
}

// ... inside the `Serialize for WireArrayData` impl:
impl Serialize for WireArrayData {
    fn serialize<S>(&self, serializer: S) -> std::result::Result<S::Ok, S::Error>
    where
        S: Serializer,
    {
        match self {
            Self::AuxIndex(index) => serializer.serialize_u64(*index as u64),
            Self::RawView(bytes) => {
                // Before: `Value::Ext(CUSTOM_TYPE_RAW_VIEW, bytes.clone()).serialize(serializer)`
                //
                // Now: borrow `bytes` without cloning.
                MsgpackExtRef((CUSTOM_TYPE_RAW_VIEW, ByteSlice(bytes))).serialize(serializer)
            }
        }
    }
}
```

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

多模态特征所有权转移：将 `mm_features` 的克隆改为 `take()`，避免大缓冲区拷贝，并调整函数签名为 `mut request`。

```

/// Convert a high-level [TextRequest] into one lower-level
/// [GenerateRequest] ready for the llm crate.
pub fn lower_text_request(
    mut request: TextRequest, // was `request: TextRequest`
    prompt_token_ids: Vec<u32>,
    sampling_hints: SamplingHints,
    sampling_limits: SamplingLimits,
    tokenizer: &dyn Tokenizer,
) -> Result<PreparedTextRequest> {
    let prompt_len = prompt_token_ids.len() as u32;
    validate_prompt_token_ids(&prompt_token_ids, &sampling_limits)?;

    let generate_request = GenerateRequest {
        request_id: request.request_id.clone(),
        prompt_token_ids,
        // Before: `mm_features: request.mm_features.clone()` caused an extra
        // allocation of the potentially-large multimodal tensor bytes.
        // After: move the feature data into the engine request so the retained
        // `text_request` no longer holds it — matching Python's response path.
        mm_features: request.mm_features.take(),
        sampling_params: lower_sampling_params(/* ... */)?,
        // ... other fields unchanged ...
        arrival_time: None,
        trace_headers: None,
    };

    Ok(PreparedTextRequest {
        text_request: request, // `mm_features` is now `None` here
        generate_request,
    })
}

```

评论区精华

- BugenZhao 询问 `ByteSlice` newtype 是否必要。
- reidliu41 解释：若没有它，`&[u8]` 会走 `Serde` 的切片序列化路径（序列化），而不是 `serialize_bytes`，导致 `_ExtStruct` 无法正确编码。使用 `newtype` 可在不引入 `serde_bytes` 依赖的前提下强制字节编码。
- BugenZhao 随后批准 PR。

风险与影响

风险：极低。线格式通过单元测试验证保证完全一致；不改变 `engine` 行为；不引入新的依赖。唯一需要关注的是 `ByteSlice` 的借字节生命周期：必须确保 `bytes` 引用在序列化期间有效，但当前用法中 `bytes` 来自 `WireArrayData::RawView` 的引用，其生命周期与 `WireArrayData` 实例一致，安全。

影响：直接影响 Rust 前端处理多模态请求时的性能，对大 `buffer` 请求（如图像）减少两次分配和拷贝。对 Python 前端和 `engine` 侧无影响。

关联脉络

- 关联 PR#47787 同样修改了 lower.rs 等 Rust 前端文件，属于同一 Rust 前端请求路径优化系列。
- 本 PR 与近期 [Rust Frontend] Stamp arrival_time at the frontend entry (#47787) 一同表明团队正在持续打磨 Rust 前端的请求处理流水线，减少非必要开销。