

PR #47787 完整报告

vllm-project/vllm

[Rust Frontend] Stamp `arrival\_time` at the frontend entry

合并时间: 2026-07-07 11:27

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47787>

执行摘要

本 PR 将 Rust 前端的 `arrival_time` 标记时机从渲染 / 分词后前移到请求入口处, 修复了 TTFT 和 e2e 直方图偏短的问题, 使 Rust 前端的时间指标与 Python 前端完全对齐。变更涉及 10 个文件, 主要是在 `generate_inner` 和 `chat` 方法开头 stamp 时间戳, 并在下游透传。

功能与动机

PR body 明确说明 *Python stamps it at the renderer entry, before both. So Rust's TTFT and e2e histograms run short.* 该变更是为了匹配 Python 前端的指标收集行为。关联 RFC #44757 和 roadmap #44280, 是 Rust 前端请求追踪功能的第一步。

实现拆解

- 可见性提升: 在 `request_metrics.rs` 中将 `current_unix_timestamp_secs` 的可见性从 `pub(crate)` 提升为 `pub`, 并删除 `request.rs` 中的私有实现, 改为统一导入。
- 字段新增: 在 `TextRequest` 结构体中增加 `arrival_time: Option<f64>` 字段, 默认为 `None`。
- 入口 stamp: 在 `text/src/lib.rs` 的 `generate_inner` 方法开头, 若未设置 `arrival_time` 则调用 `current_unix_timestamp_secs` 填充; 在 `chat/src/lib.rs` 的 `chat` 方法开头直接计算时间戳并传入。
- 下游透传: `lower.rs` 中将 `arrival_time` 从硬编码 `None` 改为从 `request` 直接透传, 并添加两项单元测试。
- 服务层适配: gRPC 和 HTTP 入口点 (`server/src/` 下的三个 `convert.rs`) 在构建 `TextRequest` 时传入 `arrival_time`。

rust/src/text/src/lower.rs

核心变更: 在 `lower_text_request` 中透传 `arrival_time`, 并添加两项测试验证透传和缺失行为

```
/// Convert a high-level TextRequest into GenerateRequest.
pub fn lower_text_request(
    request: TextRequest,
    prompt_token_ids: Vec<u32>,
    sampling_hints: SamplingHints,
    sampling_limits: SamplingLimits,
    tokenizer: &dyn Tokenizer,
) -> Result<PreparedTextRequest> {
    // ... 省略前置验证 ...
    let generate_request = GenerateRequest {
```

```

        request_id: request.request_id.clone(),
        prompt_token_ids,
        mm_features: request.mm_features.clone(),
        sampling_params: lower_sampling_params(/* ... */)?,
        cache_salt: request.cache_salt.clone(),
        priority: request.priority,
        data_parallel_rank: request.data_parallel_rank,
        reasoning_parser_kwargs: request.reasoning_parser_kwargs.clone(),
        lora_request: request.lora_request.clone(),
        arrival_time: request.arrival_time, // 透传, 不再硬编码为 None
        trace_headers: None,
    };
    Ok(PreparedTextRequest { text_request: request, generate_request })
}

```

// 测试: 验证透传

#[test]

```

fn lower_text_request_passes_arrival_time_through() {
    let request = TextRequest { arrival_time: Some(42.5), ..sample_request() };
    let prepared = lower_text_request(
        request,
        vec![1, 2, 3],
        sample_sampling_hints(),
        sample_sampling_limits(),
        &stub_tokenizer(),
    )
    .unwrap();
    assert_eq!(prepared.generate_request.arrival_time, Some(42.5));
}

```

// 测试: 验证缺失时保持 None

#[test]

```

fn lower_text_request_leaves_arrival_time_unset_when_absent() {
    let request = TextRequest { arrival_time: None, ..sample_request() };
    let prepared = lower_text_request(
        request,
        vec![1, 2, 3],
        sample_sampling_hints(),
        sample_sampling_limits(),
        &stub_tokenizer(),
    )
    .unwrap();
    assert_eq!(prepared.generate_request.arrival_time, None);
}

```

[rust/src/text/src/lib.rs](#)

在 `generate_inner` 入口处填充默认 `arrival_time`, 实现前移标记

```

async fn generate_inner(

```

```
&self,
mut request: TextRequest,
) -> Result<(TextRequest, GenerateOutputStream)> {
    request.validate()?;

    // 在 render 和 tokenization 之前标记 arrival_time, 以匹配 Python 行为
    if request.arrival_time.is_none() {
        request.arrival_time = Some(vllm_llm::current_unix_timestamp_secs());
    }

    let tokenizer = self.backend.tokenizer();
    let prompt_token_ids = match take(&mut request.prompt) {
        Prompt::Text(text) => tokenizer.encode(&text, request.add_special_tokens)?,
        Prompt::TokenIds(token_ids) => token_ids,
    };
    // ... 后续 lower 和 generate ...
}
```

评论区精华

无实质讨论，维护者 BugenZhao 直接批准并回复“Thanks!”。

风险与影响

- 风险：低。TTFT 和 e2e 直方图会因包含渲染和分词时间而变长，但这是预期行为。如果监控系统基于旧阈值告警，需要更新基线。
- 影响：所有 Rust 前端请求的时间指标将被修正，与 Python 前端一致；无性能或协议影响。

关联脉络

本 PR 是 RFC #44757（Rust 前端请求追踪）Phase 1 的第一项变更，后续会有更多 PR 引入 OpenTelemetry tracing 支持。