

# PR #47444 完整报告

vllm-project/vllm

[Rust Frontend] Cache metric handles for scheduler & request stats

合并时间: 2026-07-06 21:03

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47444>

## 执行摘要

本 PR 在 Rust frontend 的 metrics 路径中引入 handles 缓存机制，避免每次记录指标时重复 `get_or_create`。通过预解析 scheduler 和 request-level 的 metrics handles 并缓存在 `SchedulerStatsRecorder` 和 `RequestMetricHandles` 中，显著降低开销。改动涉及 9 个文件，净增 343 行删除 237 行，核心逻辑在 `rust/src/llm/src/request_metrics.rs` 和 `rust/src/engine-core-client/src/metrics.rs`。

## 功能与动机

根据 PR 描述: "This PR reduces repeated `get_or_create` lookups on scheduler & request-level metrics paths. Instead of calling `get_or_create` every time when we want to access the global metrics handle for a request, we pre-resolve per-engine metrics handles once `ClientInner` and `GenerateOutputStream` are created, and cache them for future use." 动机是消除每次指标记录时的哈希查找和潜在锁竞争，提升性能。

## 实现拆解

1. 引入 `SchedulerStatsRecorder`: 在 `rust/src/engine-core-client/src/metrics.rs` 中新增结构体，包含 `BTreeMap<u32, SchedulerStatsHandles>`。构造时遍历所有 engine，调用 `resolve_scheduler_stats_handles` 预解析 handles，提供 `record` 方法缓存查找。原有 `record_scheduler_stats` 函数被替代。
2. 重构 `RequestMetricsTracker`: 在 `rust/src/llm/src/request_metrics.rs` 中新增 `RequestMetricHandles`，缓存请求所有固定标签 handles。`new` 方法增加 `engine_index` 参数，初始化时预解析 handles。`observe_output` 等方法直接使用缓存 handles，不再传递 `engine_index`。
3. 传递 `engine_index`: 在 `rust/src/engine-core-client/src/client/stream.rs` 中为 `EngineCoreOutputStream` 添加 `engine_index` 字段；在 `rust/src/llm/src/lib.rs` 中调整创建顺序：先调用 `client.call` 获取 stream，再基于 `stream.engine_index()` 创建 `RequestMetricsTracker`。
4. 简化输出流: `rust/src/llm/src/output.rs` 中 `GenerateOutputStream` 的 `poll_next` 调用 `observe_output` 不再传入 `engine_index`。
5. 测试适配: `rust/src/llm/tests/generate.rs` 相应调整。

## 关键源码片段

## rust/src/llm/src/request\_metrics.rs

核心文件：引入 RequestMetricHandles 结构体缓存所有请求级 metrics handles，重构 RequestMetricsTracker 使其在构造时预解析 handles，所有方法直接使用缓存 handles 而非重复 get\_or\_create。

```
/// 预解析并缓存请求级 metrics handles，避免每次记录时重复 get_or_create。
```

```
#[derive(Clone)]
```

```
struct RequestMetricHandles {
```

```
    labels: EngineLabels,
```

```
    // 请求级别计数器
```

```
    num_preemptions: U64Counter,
```

```
    prompt_tokens: U64Counter,
```

```
    prompt_tokens_local_compute: U64Counter,
```

```
    prompt_tokens_local_cache_hit: U64Counter,
```

```
    prompt_tokens_external_kv_transfer: U64Counter,
```

```
    prompt_tokens_cached: U64Counter,
```

```
    generation_tokens: U64Counter,
```

```
    // 请求生命周期指标（直方图等）
```

```
    request_success: Family<FinishedReasonLabels, U64Counter>,
```

```
    request_prompt_tokens: HistogramMetric,
```

```
    request_generation_tokens: HistogramMetric,
```

```
    request_max_num_generation_tokens: HistogramMetric,
```

```
    request_params_max_tokens: HistogramMetric,
```

```
    request_params_n: HistogramMetric,
```

```
    request_prefill_kv_computed_tokens: HistogramMetric,
```

```
    time_to_first_token_seconds: HistogramMetric,
```

```
    inter_token_latency_seconds: HistogramMetric,
```

```
    e2e_request_latency_seconds: HistogramMetric,
```

```
    request_queue_time_seconds: HistogramMetric,
```

```
    request_prefill_time_seconds: HistogramMetric,
```

```
    request_decode_time_seconds: HistogramMetric,
```

```
    request_inference_time_seconds: HistogramMetric,
```

```
    request_time_per_output_token_seconds: HistogramMetric,
```

```
}
```

```
impl RequestMetricsTracker {
```

```
    pub(crate) fn new(
```

```
        model_name: String,
```

```
        engine_index: u32, // 新增 engine_index 参数
```

```
        arrival_time: f64,
```

```
        prompt_len: u32,
```

```
        max_tokens_param: Option<u32>,
```

```
        n_param: u32,
```

```
    ) -> Self {
```

```
        Self {
```

```
            // 在构造时预解析所有 handles
```

```

        handles: resolve_request_metric_handles(&model_name, engine_index),
        arrival_time,
        prompt_len,
        max_tokens_param,
        n_param,
        is_prefilling: true,
        queued_ts: 0.0,
        scheduled_ts: 0.0,
        first_token_ts: 0.0,
        last_token_ts: 0.0,
        first_token_latency: 0.0,
        num_generation_tokens: 0,
        latest_num_cached_tokens: 0,
    }
}

pub(crate) fn observe_output(
    &mut self,
    batch_timestamp: f64,
    received_at: f64,
    output: &EngineCoreOutput,
) {
    // 直接使用缓存的 handles, 无需每次 get_or_create
    self.handles.generation_tokens.inc_by(output.new_token_ids.len() as u64);
    // ... 简化, 不再传递 engine_index
}
}

```

## rust/src/engine-core-client/src/metrics.rs

核心文件：引入 SchedulerStatsRecorder 结构体，预解析所有 scheduler stats 的 handles，提供 record 方法替代原有函数。

/// 缓存 scheduler stats 的 metric handles, 按 engine 索引存储。

```

pub(crate) struct SchedulerStatsRecorder {
    engines: BTreeMap<u32, SchedulerStatsHandles>,
}

```

/// 单个 engine 的缓存的 metric handles。

```

struct SchedulerStatsHandles {
    labels: EngineLabels,
    scheduler_running: U64Gauge,
    scheduler_waiting: U64Gauge,
    scheduler_waiting_capacity: U64Gauge,
    scheduler_waiting_deferred: U64Gauge,
    kv_cache_usage: F64Gauge,
    prefix_cache_queries: U64Counter,
    prefix_cache_hits: U64Counter,
    external_prefix_cache_queries: U64Counter,
    external_prefix_cache_hits: U64Counter,
}

```

```

spec_decode_num_drafts: U64Counter,
spec_decode_num_draft_tokens: U64Counter,
spec_decode_num_accepted_tokens: U64Counter,
spec_decode_num_accepted_tokens_per_pos: Family<EnginePositionLabels, U64Counter>,
estimated_flops_per_gpu: U64Counter,
estimated_read_bytes_per_gpu: U64Counter,
estimated_write_bytes_per_gpu: U64Counter,
kv_block_lifetime_seconds: HistogramMetric,
kv_block_idle_before_evict_seconds: HistogramMetric,
kv_block_reuse_gap_seconds: HistogramMetric,
log_stats: SchedulerLogStatsAccumulator,
}

impl SchedulerStatsRecorder {
    /// 在构造时遍历所有 engine，预解析 handles。
    pub(crate) fn new(
        metrics: &SchedulerMetrics,
        model_name: &str,
        engines: &[ConnectedEngine],
    ) -> Self {
        let engines = engines
            .iter()
            .filter_map(|engine| {
                let engine = engine.engine_id.engine_index()?;
                Some((
                    engine,
                    resolve_scheduler_stats_handles(metrics, model_name, engine),
                ))
            })
            .collect();
        Self { engines }
    }

    /// 记录 scheduler stats，直接使用缓存 handles。
    pub(crate) fn record(&self, engine_index: u32, stats: &SchedulerStats) {
        if let Some(handles) = self.engines.get(&engine_index) {
            record_scheduler_stats_with_handles(handles, stats);
        }
    }
}

```

## 评论区精华

没有实质性的技术讨论。PR 仅获得 njhill 的 approve 以及机器人自动评论（合并冲突和 pre-commit 提醒）。

## 风险与影响

- 风险：handles 缓存与底层 metrics 注册表一致；若 engine 在运行时动态增减（如 DP 扩容），SchedulerStatsRecorder 无法自动感知，需重建；动态标签指标（如 spec decoding per position）仍存在 child lookup 开销。
- 影响：对用户透明，提升 Rust frontend metrics 记录性能。改动涉及多个文件但逻辑单一，回归风险较低。

## 关联脉络

该 PR 属于 git-spice 管理的 stack 的一部分（关联 #47435）。未发现与同仓库近期其他 PR 直接关联。