

PR #48992 完整报告

vllm-project/vllm

[Rust Frontend][gRPC] Add engine-aware health reporting

合并时间: 2026-07-21 10:54

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/48992>

执行摘要

本 PR 在 Rust 前端 gRPC 监听器上注册了标准的 `grpc.health.v1.Health` 服务，通过 `EngineCoreClient` 的 Tokio watch 通道接收引擎健康变更，并将健康状态报告为 `SERVING`（启动后）或 `NOT_SERVING`（引擎不健康或关闭时）。同时保持了活跃健康流的持续交付，并在 graceful shutdown 时正确关闭。没有新增端口或监听器。

功能与动机

PR 目的是补充 Rust 前端缺失的标准 gRPC 健康检查端点。目前 `vLLM` 的 gRPC 服务只提供 `vllm.Generate`，外部监控与负载均衡工具无法通过 gRPC 标准协议获取服务器健康状态。此变更实现 `grpc.health.v1.Health` 协议，使基础设施可以依赖统一健康检查。

实现拆解

- 引擎客户端扩展：在 `rust/src/engine-core-client/src/client/imp.rs` 中添加 `health_tx`: `watch::Sender<bool>` 字段，初始化为 `true`；提供 `subscribe_health()` 返回接收器；在 `close_registries()` 中调用 `publish_unhealthy()` 发送 `false`，实现 sticky 不健康转换。
- 健康监控模块：新建 `rust/src/server/src/grpc/health.rs`，包含 `monitor_health` 异步函数，通过 `tokio::select!` 等待引擎不健康或关闭信号，然后设置 `HealthReporter` 状态为 `NOT_SERVING`，并在关闭后清理服务状态。
- 服务器集成：在 `rust/src/server/src/lib.rs` 中，当启用 gRPC 端口时，创建 `tonic_health::server::health_reporter()` 并订阅引擎健康；将健康服务和生成服务注册到同一 gRPC 服务器；通过 `tokio::join!` 并发运行服务器和健康监控任务。
- 测试配套：在 `tests.rs` 中新增 `start_grpc_test_server` 辅助函数，以及两个集成测试：验证引擎不健康时健康状态转换为 `NOT_SERVING`，验证优雅关闭时健康 watch 正确结束。
- 依赖更新：修改 `rust/Cargo.toml` 和 `rust/src/server/Cargo.toml` 添加 `tonic-health` 依赖，并统一其他 tonic 相关版本至 0.14.6。

`rust/src/server/src/grpc/health.rs`

核心新增文件，实现了基于引擎状态的 gRPC 健康监控逻辑

```
// SPDX-License-Identifier: Apache-2.0
// SPDX-FileCopyrightText: Copyright contributors to the vLLM project

use tokio::sync::watch;
use tokio_util::sync::CancellationToken;
```

```

use tonic::server::NamedService;
use tonic_health::ServingStatus;
use tonic_health::server::HealthReporter;
use tracing::{info, warn};

use super::GenerateGrpcService;

/// 监控引擎健康状态，并驱动 gRPC 健康报告。
/// 当引擎不健康或收到关闭信号时，将服务状态标记为 NOT_SERVING。
pub(crate) async fn monitor_health(
    mut health_reporter: HealthReporter,
    mut engine_health: watch::Receiver<bool>,
    shutdown: CancellationToken,
) {
    let generate_service = GenerateGrpcService::NAME;
    let status = ServingStatus::NotServing;
    // 等待引擎健康变为 false 或 shutdown 触发
    let health_event_first = tokio::select! {
        result = engine_health.wait_for(|healthy| !*healthy) => {
            match result {
                Ok(_) => warn!(
                    generate_service,
                    overall_service = true,
                    status = ?status,
                    reason = "engine_unhealthy",
                    "标记 gRPC 健康服务为不可用（引擎不健康）",
                ),
                Err(error) => warn!(
                    %error,
                    generate_service,
                    overall_service = true,
                    status = ?status,
                    reason = "health_channel_closed",
                    "引擎健康通道关闭，标记 gRPC 健康服务为不可用",
                ),
            }
        },
        true // 引擎健康事件先发生
    }
    _ = shutdown.cancelled() => {
        info!(
            generate_service,
            overall_service = true,
            status = ?status,
            reason = "server_shutdown",
            "服务器关闭中，标记 gRPC 健康服务为不可用"
        );
        false // shutdown 先触发
    }
};

```

```

// 设置服务状态为 NOT_SERVING
health_reporter.set_not_serving::<GenerateGrpcService>().await;
// 整体服务镜像 Generate 服务状态
health_reporter.set_service_status("", status).await;

if health_event_first {
    // 如果是引擎事件先发生，等待关闭完成再关闭 watch
    shutdown.cancelled().await;
    info!(
        generate_service,
        overall_service = true,
        reason = "server_shutdown",
        "服务器关闭中，关闭 gRPC 健康 watch"
    );
}

// 清理服务状态，确保客户端收到终止
health_reporter.clear_service_status(generate_service).await;
health_reporter.clear_service_status("").await;
}

```

rust/src/engine-core-client/src/client/imp.rs

引擎客户端核心实现，添加 health_tx 字段和订阅 / 发布方法

```

// 在 ClientInner 中添加 health_tx 字段
pub(crate) struct ClientInner {
    // ... existing fields ...
    health_error: ArcSwapOption<Error>,
    /// 通过 watch 通道向外部传播健康状态变化。
    /// 初始值为 `true`，一旦引擎失败变为 `false` 并保持。
    health_tx: watch::Sender<bool>,
}

impl ClientInner {
    pub fn new(/* ... */) -> Self {
        // ... existing init ...
        Self {
            // ...
            health_error: ArcSwapOption::empty(),
            health_tx: watch::Sender::new(true), // 初始健康
        }
    }

    /// 订阅引擎健康变化。返回的 Receiver 当前值为 `true`，
    /// 在引擎永久失败后变为 `false`。
    pub fn subscribe_health(&self) -> watch::Receiver<bool> {
        self.health_tx.subscribe()
    }

    /// 当引擎发生第一个持久性健康错误时，发布健康转换。

```

```

/// 使用 `send_if_modified` 确保只从 `true` 变为 `false` 一次。
fn publish_unhealthy(&self) {
    self.health_tx.send_if_modified(|healthy| std::mem::replace(healthy, false));
}

/// 关闭所有注册表并发布不健康状态
pub fn close_registries(&self, error: Arc<Error>) {
    let persistent_error = self.record_health_error(error);
    // 在关闭请求和工具注册表之前发布不健康信号,
    // 以便健康 watch 接收者能尽早得知状态变化。
    self.publish_unhealthy();
    let request_senders = self.request_reg.lock().close();
    let utility_senders = self.utility_reg.lock().close();
    // ... 关闭发送器 ...
}
}

```

评论区精华

- 提取到独立文件：BugenZhao 建议将 `monitor_health` 从 `lib.rs` 提取到 `grpc` 子模块。作者创建了 `health.rs`，已解决。
- 简化 `publish_unhealthy`：njhill 提出使用 `send_if_modified` 模式简化实现。作者采纳并修改。
- 统一 tonic 版本：njhill 建议将所有 tonic 依赖升级到 0.14.6。作者在 `Cargo.toml` 中统一了版本。

风险与影响

风险较低。主要风险在于健康报告完全依赖引擎健康状态的转换，如果引擎健康检测逻辑本身存在缺陷，可能导致错误报告。新代码使用 tonic-health 标准库，稳定性高。影响范围限于 Rust 前端 gRPC 服务，对外暴露标准健康端点，提升可观测性。团队需关注新依赖的版本兼容。

关联脉络

没有发现与近期历史 PR 的直接关联。此 PR 是 Rust 前端在可观测性方面的重要补充，为后续更丰富的监控功能奠定基础。对于部署在 Kubernetes 等服务网格环境的用户，标准健康检查端点可直接用于就绪探针和存活探针。