

PR #46696 完整报告

vllm-project/vllm

[Rust Frontend] Switch `rustls` to `native-tls`/OpenSSL

合并时间: 2026-06-26 08:19

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46696>

执行摘要

- 一句话: 将 Rust 前端的 TLS 实现从 rustls 切换到 native-tls/OpenSSL, 并添加依赖禁止检查。
- 推荐动作: 该 PR 值得关注其依赖治理策略, 特别是通过 cargo-deny 建立禁止列表和利用 Cargo feature unification 确保 TLS 一致性的方法。适合作为基础设施团队依赖管理的参考案例。

功能与动机

PR body 明确指出: 'Eliminate rustls from the Rust frontend dependency tree and keep the HTTP/TLS stack on native-tls / OpenSSL, which is friendlier for compliance-sensitive deployments.' 此外还引用了 issue #46052 和 PR #45890 的讨论。

实现拆解

1. 调整工作空间依赖配置: 在 rust/Cargo.toml 中, 将 reqwest、async-openai、openai-harmony 的 TLS 后端从 rustls-tls 切换为 native-tls; 禁用 hf-hub 的默认特性并仅启用 tokio 特性, 避免其传递引入 rustls; 升级 fasttokens 到 0.2.1 并禁用默认特性, 消除其对同步 hf-hub API 的依赖; 更新 llm-multimodal 到新 commit 以获取 native-tls 支持。
2. 适配 tokenizer 基准测试: rust/src/tokenizer/benches/tiktoken.rs 和 rust/src/tokenizer/benches/hf.rs 中的模型加载函数 tiktoken_model 和 tokenizer_json 原先使用 hf_hub::api::sync::ApiBuilder 同步 API, 现改为使用 hf_hub::api::tokio::ApiBuilder 并通过 tokio::runtime::Runtime::block_on 在同步上下文中执行异步调用。
3. 新增依赖禁止配置: 创建 rust/deny.toml, 配置 cargo-deny 的 bans 检查, 禁止引入 rustls、ring、aws-lc-rs、aws-lc-sys、s2n-tls、s2n-tls-sys、boring、boring-sys 等 crate。
4. 集成 CI 检查: 在 .buildkite/scripts/run-rust-frontend-cargo-ci.sh 中新增 install_cargo_deny 函数, 并在 run_style_clippy 步骤中添加 cargo deny check bans 命令, 确保每次 CI 都会执行依赖禁止检查。
5. 更新 lock 文件: rust/Cargo.lock 删除大量与 rustls 相关的包条目, 反映依赖树的净减少 (+21/-417)。

关键文件:

- rust/src/tokenizer/benches/tiktoken.rs (模块 tokenizer 测试; 类别 source; 类型 dependency-wiring; 符号 tiktoken_model) : 此基准测试因 hf-hub API 从同步改为异步而调整, 使用 tokio runtime 包裹调用, 体现了依赖变更对测试代码的影响。
- rust/src/tokenizer/benches/hf.rs (模块 tokenizer 测试; 类别 source; 类型 dependency-wiring; 符号 tokenizer_json) : 与文件 1 类似, 将同步 hf-hub API 改为异步, 影响 HuggingFace tokenizer 基准测试加载模型文件的方式。
- rust/deny.toml (模块 Rust 配置; 类别 config; 类型 configuration) : 新文件, 配置 cargo-deny 的 bans 规则, 禁止引入与 native-tls 冲突的 TLS crate, 是本次变更的治理核心。
- rust/Cargo.toml (模块 Rust 配置; 类别 config; 类型 configuration) : 工作空间依赖配置的主文件, 核心变更都在这里: 切换 reqwest 等 crate 的 TLS 特性, 修改 fastokens、hf-hub、openai-harmony、async-openai 等的依赖声明, 是本次 PR 的核心配置变更。
- .buildkite/scripts/run-rust-frontend-cargo-ci.sh (模块 CI 脚本; 类别 other; 类型 core-logic; 符号 install_cargo_deny, run_style_clippy) : CI 脚本, 新增 cargo-deny 安装和运行步骤, 将依赖禁止检查纳入 CI 流程, 防止未来回归。

关键符号: install_cargo_deny, tiktoken_model, tokenizer_json

关键源码片段

rust/deny.toml

新文件, 配置 cargo-deny 的 bans 规则, 禁止引入与 native-tls 冲突的 TLS crate, 是本次变更的治理核心。

```
# 允许同一个 crate 的多个版本 (仅用于过渡, 未来应设为 deny)
multiple-versions = 'allow'
```

```
# 禁止引入以下 TLS/crypto 库, 以保持唯一 native-tls 后端
deny = [
  { name = 'rustls' }, # 纯粹的 Rust TLS 实现
  { name = 'ring' }, # rustls 底层加密库
  { name = 'aws-lc-rs' }, # AWS-LC 的 Rust 绑定
  { name = 'aws-lc-sys' }, # AWS-LC 系统库
  { name = 's2n-tls' }, # AWS s2n-tls 实现
  { name = 's2n-tls-sys' }, # s2n-tls 系统库
  { name = 'boring' }, # BoringSSL 的 Rust 绑定
  { name = 'boring-sys' }, # BoringSSL 系统库
]
```

评论区精华

供应链风险: depthfirst-app[bot] 指出 openai-harmony 从 crates.io 切换为第三方 git fork 可能破坏完整性验证。TLS 完整性: chatgpt-codex-connector[bot] 指出 hf-hub 禁用默认特性后可能缺失 TLS。作者 BugenZhao 回复通过确保 vllm-text 和 vllm-tokenizer 显式依赖 reqwest/native-tls 利用特性统一解决。运行时依赖: Harry-Chen 担忧 libssl.so 动态链接。作者确认 native-tls-vendored 静态链接无运行时依赖。

- 引入 openai-harmony git 依赖的供应链风险 (security): PR 最终合并, 说明团队评估后接受了此风险, 或已确认 fork 可信。
- hf-hub default-features=false 可能导致 TLS 缺失 (correctness): 作者 BugenZhao 回复同意, 并指出不能直接在 hf-hub 上添加 native-tls 特性 (因为会引入 ureq 和 rustls), 而是需要在 vllm-text 和 vllm-tokenizer 中显式依赖 reqwest/native-tls, 利用 Cargo 特性统一机制。后续 commit 中已确保 hf-hub 独立 TLS 后端。
- 对 libssl.so 运行时依赖的担忧 (question): 作者回复已启用 native-tls-vendored 特性, 静态链接 OpenSSL, 因此不会产生动态库依赖。

风险与影响

- 风险:
 - 供应链风险: openai-harmony 改用第三方 git fork (Inferact/openai-harmony), pinned commit 可能不可追溯, 增加安全审计负担。
 - 构建体积: native-tls-vendored 静态链接 OpenSSL 会增大 Rust 二进制体积, 但影响有限。
 - 依赖治理维护: deny.toml 禁止列表需要随依赖更新维护, 可能误拦合法依赖 (如未来若有合理使用 rustls 的场景)。
 - 基准测试变化: tokenizer bench 从同步改为异步调用, 可能引入微小延迟, 但 block_on 仅在初始化时执行一次, 对基准影响可忽略。
 - 影响: 影响范围局限于 Rust 前端构建产物 (vllm-chat、vllm-text、vllm-tokenizer 等 crate), Python 后端无影响。对用户完全透明, 但使 Docker 镜像和 wheel 中的 TLS 实现统一为 OpenSSL, 有利于合规审核。对开发团队, 需要维护 deny.toml 并在添加新依赖时确认 TLS 后端类型。
 - 风险标记: 供应链风险 (git 依赖), 构建体积增大 (vendored OpenSSL), 依赖治理维护成本

关联脉络

- PR #46052 : PR body 引用此 issue 作为相关讨论, 涉及 TLS 选择的决策背景。
- PR #45890 : PR body 引用此 PR 的 comment (#issuecomment-4783509287) 作为相关讨论。