

PR #52593 完整报告

vllm-project/vllm

[Build] Propagate vLLM version to Rust binaries

合并时间: 2026-08-18 14:37

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/52593>

执行摘要

- 一句话: 构建系统将 vLLM 源版本注入 Rust 二进制与版本接口
- 推荐动作: 值得精读。该 PR 展示了跨语言构建链路中版本信息传递的完整设计: 以 `setuptools_scm` 为单一事实来源, 通过环境变量注入 Rust 编译期常量, 并在 Docker 多阶段构建中优雅处理 Git 元数据缺失 (`.git` 与 `.git_archival.txt` 兼容) 与 `partial worktree` 误判 `dirty` 的问题。对于从事 vLLM 构建系统、Rust 前端或 Docker 镜像维护的工程师, 本 PR 的 `prepare_build_environment` 函数和 `build-info` crate 模式可直接作为版本注入的参考实现。

功能与动机

PR body 明确指出: Rust artifacts currently identify themselves using workspace crate metadata, which stays at `0.1.0` and does not identify the corresponding nightly or release vLLM source revision. 这意味着用户无法从 Rust 侧工具版本追溯到对应的 vLLM 源码修订, 影响排障和版本对齐。该 PR 在编译 Rust 前解析源版本, 并通过 `VLLM_RS_BUILD_VERSION` 传入, 同时让 `get_vllm_version()` 先于 Rust 构建执行, 使 `VLLM_VERSION_OVERRIDE` 经 `SETUPTOOLS_SCM_PRETEND_VERSION` 同样作用于 Rust 工件。

实现拆解

1. 版本解析入口: 在 `tools/build_rust.py` 中新增 `prepare_build_environment()`, 优先读取 `VLLM_RS_BUILD_VERSION` 环境变量, 否则调用 `setuptools_scm.get_version(root=ROOT_DIR)` 从 Git 元数据解析源版本, 并将结果写回环境变量; `main()` 在 `build_binary()` 前调用该函数, 让本地 `bash build_rust.sh` 和 `setuptools-rust` 构建路径都拿到版本。
2. Python 打包时序保证: 在 `setup.py` 的 `setup()` 调用前先执行 `vllm_version = get_vllm_version()`, 再执行 `rust_build.prepare_build_environment()`。这是因为 `get_vllm_version()` 可能设置 `SETUPTOOLS_SCM_PRETEND_VERSION`, 而 `prepare_build_environment()` 内部依赖该变量来解析出与 Python 包一致的版本, 保证 `nightly/release wheel` 构建中 Rust 版本与 Python 版本同步。
3. Rust 侧版本接入: 新增 `rust/src/build-info` crate, 在 `lib.rs` 中定义 `pub const VERSION: &str`, 优先读取编译期环境变量 `VLLM_RS_BUILD_VERSION`, 缺失时回退到 `CARGO_PKG_VERSION` (`0.1.0`)。随后将 `vllm-build-info` 加入 `rust/Cargo.toml` workspace, 并为 `rust/src/cmd/Cargo.toml`、`rust/src/bench/Cargo.toml` 添加依赖;

vllm-rs 和 vllm-bench 的 clap `#[command(version = vllm_build_info::VERSION)]` 改为使用该常量, rust/src/server/src/routes/version.rs 的 rust_frontend_version 字段同样改为该常量, 引擎上报的 version 字段保持不变。

4. Docker 构建路径适配: 在 docker/Dockerfile、.cpu、.rocm、.rocm_gfx1250、.xpu 中增加获取源码版本逻辑。由于 selective-copy 阶段会省略部分 tracked 文件, 若不处理会让 Git 错误地把 partial worktree 标记为 dirty, 因此构建阶段显式设置 `dirty=false`。ROCm 场景因镜像可能不携带 .git (为减小体积和优化缓存), BugenZhao 新增了一个轻量共享stage, 调用 `setuptools_scm` 自动区分 `git` 存在或仅存在 `git_archival.txt` 的情况。`.buildkite/scripts/ci-bake-rocm.sh` 同步调整了 bake 时的版本解析参数。
5. 测试与验证配套: `tests/entrypoints/openai/test_uds.py` 和 `tests/entrypoints/serve/instrumentator/test_basic.py` 在启用 `VLLM_USE_RUST_FRONTEND` 时新增断言 `rust_frontend_version == VLLM_VERSION`; Rust 端 `rust/src/server/src/routes/tests.rs` 的版本路由测试改为断言 `vllm_build_info::VERSION`。作者在 CI 中验证 CUDA/ROCm/CPU 镜像的 Rust 二进制均报告 `0.27.2rc1.dev192+g2db2a2484`, 准确对应源提交。

关键文件:

- `tools/build_rust.py` (模块 构建工具; 类别 source; 类型 dependency-wiring; 符号 `prepare_build_environment`): 新增 `prepare_build_environment()`, 是版本解析与注入的入口, 负责从 `setuptools-scm` 解析源版本并写入 `VLLM_RS_BUILD_VERSION` 环境变量, 决定整个构建链的版本来源。
- `rust/src/build-info/src/lib.rs` (模块 构建信息; 类别 source; 类型 core-logic): 新增的 `vllm-build-info` crate 是 Rust 侧版本暴露的核心, 通过 `VERSION` 常量统一了 `vllm-rs`、`vllm-bench` 和 Rust 前端 `/version` 接口的版本来源。
- `setup.py` (模块 打包脚本; 类别 source; 类型 core-logic): 调整 Python 打包时序: 先调用 `get_vllm_version()` 再调用 `prepare_build_environment()`, 确保 `VLLM_VERSION_OVERRIDE` 经 `SETUPTOOLS_SCM_PRETEND_VERSION` 传递给 Rust 构建, 是 wheel 构建路径版本一致性的关键。
- `rust/src/cmd/src/cli.rs` (模块 命令行入口; 类别 source; 类型 core-logic): `vllm-rs` 的 clap 命令版本由默认 crate 版本改为 `vllm_build_info::VERSION`, 使 `vllm-rs --version` 输出真实 `vLLM` 源版本。
- `rust/src/bench/src/main.rs` (模块 基准工具; 类别 source; 类型 core-logic): `vllm-bench` 的 clap 版本由 `version` (自动使用 crate 版本) 改为显式绑定 `vllm_build_info::VERSION`, 使基准工具报告源版本。
- `rust/src/server/src/routes/version.rs` (模块 版本接口; 类别 source; 类型 endpoint): Rust 前端 `GET /version` 的 `rust_frontend_version` 字段从 `CARGO_PKG_VERSION` 改为 `vllm_build_info::VERSION`, 是用户可观测的版本接口。
- `docker/Dockerfile.rocm` (模块 镜像构建; 类别 infra; 类型 infrastructure): ROCm 镜像可能不携带 `.git`, 本 PR 在这里新增轻量 `setuptools-scm` 共享 stage 以兼容 `.git / .git_archival.txt` 两种元数据来源, 并设置 `dirty=false`, 是讨论中重点关注的改动。
- `tests/entrypoints/openai/test_uds.py` (模块 端到端测试; 类别 test; 类型 test-coverage): E2E 测试在 Rust 前端启用时新增 `rust_frontend_version == VLLM_VERSION` 断言, 验

证版本注入端到端生效。

关键符号: `prepare_build_environment`

关键源码片段

`tools/build_rust.py`

新增 `prepare_build_environment()`，是版本解析与注入的入口，负责从 `setuptools-scm` 解析源版本并写入 `VLLM_RS_BUILD_VERSION` 环境变量，决定整个构建链的版本来源。

```
# tools/build_rust.py 中新增的版本解析与注入逻辑
```

```
VLLM_RS_BUILD_VERSION = "VLLM_RS_BUILD_VERSION"
```

```
def prepare_build_environment() -> str | None:
    """设置 Rust 工件使用的设备无关 vLLM 源版本。"""
    # 优先读取外部显式传入的版本，例如 CI 通过环境变量指定
    version = os.getenv(VLLM_RS_BUILD_VERSION) or None
    if version is None:
        try:
            # 从 Git 元数据或 .git_archival.txt 解析源版本
            version = get_version(root=ROOT_DIR)
        except LookupError:
            # 既无 .git 也无 .git_archival.txt 时返回 None，
            # 调用方将回退到 Rust crate 版本 (0.1.0)
            return None

    # 写回环境变量，供 setuptools-rust / cargo 在编译期读取
    os.environ[VLLM_RS_BUILD_VERSION] = version
    return version


def main() -> None:
    # 必须在 build_binary 之前解析版本，
    # 否则 RustExtension 编译时拿不到 VLLM_RS_BUILD_VERSION
    prepare_build_environment()
    build_binary(sys.argv[1:])
```

`rust/src/build-info/src/lib.rs`

新增的 `vllm-build-info` crate 是 Rust 侧版本暴露的核心，通过 `VERSION` 常量统一了 `vllm-rs`、`vllm-bench` 和 Rust 前端 `/version` 接口的版本来源。

```
// rust/src/build-info/src/lib.rs

/// 构建系统注入的 vLLM 源版本。
///
/// 直接使用 `cargo build` 且未设置 `VLLM_RS_BUILD_VERSION` 时，
/// 回退到 workspace crate 版本 (0.1.0)。
```

```
pub const VERSION: &str = match option_env!("VLLM_RS_BUILD_VERSION") {
    Some(version) => version,
    None => env!("CARGO_PKG_VERSION"),
};
```

评论区精华

核心讨论围绕 ROCm 镜像的 Git 元数据可用性展开。AndreasKaratzas 提出担忧: "The problem I think is that ROCm may not ship with .git such that we reduce size and also optimize docker caching", 即 ROCm 镜像为减小体积、优化缓存通常不携带 .git, 可能导致版本解析失效。BugenZhao 回应已增加轻量共享 stage: "I've managed to add a lightweight shared stage for retrieving the version by calling `setuptools_scm` there in ROCm Dockerfile, which should automatically handle different cases like when .git is present or from `.git_archival.txt`", 并补充验证结果 "Verified that the Rust binaries from all images here (CUDA, ROCm, CPU) correctly reports `0.27.2rc1.dev192+g2db2a2484`". AndreasKaratzas 最终确认 "Yep it is indeed lightweight. ROCm modification LGTM". 该讨论已解决, 无未关闭疑虑。

- ROCm 镜像可能不携带 .git 导致版本解析失败 (design): BugenZhao 在 ROCm Dockerfile 中新增轻量共享 stage, 调用 `setuptools_scm` 自动处理 .git 存在或仅存在 `.git_archival.txt` 的情况; 验证 CUDA/ROCm/CPU 三类镜像均正确报告 `0.27.2rc1.dev192+g2db2a2484` 后, AndreasKaratzas 确认 ROCm 改动 LGTM。
- 跨平台版本一致性验证 (testing): 验证通过, 三个平台输出一致, 确认设备无关设计成立。
- pre-commit 检查与 CI 触发 (other): 经过多轮修复和重新触发, CI 全部通过。

风险与影响

- 风险: 主要风险集中在构建链路和环境依赖上: 1) 若构建环境既无 .git 也无 `.git_archival.txt`, `setuptools_scm` 会抛 `LookupError`, `prepare_build_environment()` 返回 `None`, Rust 版本将回退到 crate 版本 0.1.0, 与 Python 包版本不一致, 可能误导用户; 2) Docker selective-copy 阶段设置 `dirty=false` 会压制 `partial worktree` 的 `dirty` 标记, 使版本号不含 `dirty` 后缀, 精度略有损失; 3) `VLLM_RS_BUILD_VERSION` 是新的构建期环境变量, 直接 `cargo build` 时若未显式设置且没有 Git 元数据, 输出仍为 0.1.0, 与 `wheel` 行为存在差异; 4) 本次改动覆盖 5 个 Dockerfile (`Dockerfile`、`.cpu`、`.rocm`、`.rocm_gfx1250`、`.xpu`) 及 `bake` 脚本, 任何平台镜像构建路径的调整都可能导致构建失败或版本错误, 依赖 CI 完整验证; 5) 重新打包预编译 Rust 二进制会保留构建时嵌入的版本, 若二进制与 `wheel` 来自不同构建, 版本可能不完全同步, 属于已知且可接受的行为。运行时性能无影响。
- 影响: 对用户: `vllm-rs --version`、`vllm-bench --version` 和 Rust 前端 `GET /version` 的 `rust_frontend_version` 字段将报告真实 vLLM 源版本, 便于在问题反馈和日志排查中快速定位对应的源码修订。对系统: 无运行时行为变化, 仅影响构建期和版本报告路径; Python 分发版本 (含 CPU/CUDA/ROCm/TPU/XPU 平台后缀) 保持不变。对团队: 统一了 Python 与 Rust 工件的版本语义, 消除了 Rust 侧长期停留在 0.1.0 的盲区; 同时为 Docker 多平台构建引入了可复用的版本解析 stage, 后续新增平台镜像时可复用该模式。影响范围覆盖所有发布构建产物, 属于基础设施层的系统性改进, 但风险可控。

- 风险标记：多平台 Dockerfile 变更，Git 元数据缺失时版本回退歧义，partial worktree dirty 状态被压制，构建期环境变量依赖，预编译二进制版本与 wheel 可能不一致

关联脉络

- PR #52575 [Rust Frontend] Simplify data-parallel size ownership: 同为 Rust 前端构建与协议调整，修改了 rust/src/server 相关代码，与本 PR 在 Rust 前端构建链路上有交集，且都涉及发布二进制与版本 / 配置的传递。
- PR #52031 [Rust Frontend][gRPC] Advertise LoRA capabilities: 通过握手协议在 Rust 前端与 Python 引擎之间传递能力信息，与本 PR 通过构建环境变量传递版本信息属于同一类跨语言构建 / 协议元数据同步问题。
- PR #51208 [ROCm][AMD][Installation] add LMCache kv-connector installation and runtime packages to docker image: 修改了 docker/Dockerfile.rocm 和 buildkite/scripts/ci-bake-rocm.sh，与本 PR 在 ROCm Docker 构建路径上直接重叠，属于同一镜像构建链路的演进。