

PR #46527 完整报告

vllm-project/vllm

[ROCM][CI] Cache Rust builds by source inputs

合并时间: 2026-07-13 14:14

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46527>

执行摘要

- 一句话: ROCM CI Rust 构建缓存优化, 避免非 Rust 变更时重复编译
- 推荐动作: 推荐 CI 和构建团队精读, 特别是 Docker 多阶段缓存和内容哈希模式, 可复用于其他高频编译模块。

功能与动机

PR body 指出 ROCm Docker 路径中即使 PR 未改动 Rust 代码, Rust 构建也会被触发, 因为 `build_rixl` 阶段继承了完整的源代码树, 任何仓库变更都会导致 cargo 构建层失效。通过缩小输入范围并引入内容哈希缓存, 避免不必要的重复编译。

实现拆解

1. 分离 Rust 工具链与源码输入阶段 (`docker/Dockerfile.rocm`): 新增 `rust_toolchain_input_0/1` 和 `rust_input_0/1` 阶段, 分别使用 `scratch` 拷贝或 `git sparse-checkout` 仅获取必需的 Rust 文件, 最终通过 `REMOTE_VLLM` 参数选择本地或远程源。
2. 添加内容哈希计算与缓存参数 (`.buildkite/scripts/ci-bake-rocm.sh`): 新增 `compute_rocm_rust_content_hash` 和 `compute_rocm_rust_content_hash_if_needed` 函数, 计算 Rust 输入文件的哈希值, 并设置 `--cache-from` 和 `--cache-to` 参数将哈希写入 Docker 缓存标签。
3. 配置 HCL 缓存函数 (`docker/ci-rocm.hcl`): 新增 `get_cache_from_rocm_rust` 和 `get_cache_to_rocm_rust` 函数, 以及 `ROCM_RUST_CACHE_TO_MODE` 变量, 使 Rust 构建层的缓存可独立读取和导出。

配套修改: 将 `rust-toolchain.toml` 等文件加入 CI 基础镜像内容文件列表, 确保哈希准确。

关键文件:

- `.buildkite/scripts/ci-bake-rocm.sh` (模块 CI 脚本; 类别 `infra`; 类型 `core-logic`; 符号 `uses_rocm_rust_cache`, `compute_rocm_rust_content_hash`, `compute_rocm_rust_content_hash_if_needed`, `compute_rocm_rust_cache_ref`): 包含核心逻辑: Rust 内容哈希计算、缓存参数注入、目标判断, 是缓存生效的控制中心。
- `docker/Dockerfile.rocm` (模块 Dockerfile; 类别 `infra`; 类型 `infrastructure`; 符号 `rust_toolchain_input_0`, `rust_toolchain_input_1`, `rust-toolchain-input`, `rust_input_0`): Docker 构建定义, 重组 Rust 阶段以分离输入, 实现精确缓存依赖。

- docker/ci-rocm.hcl (模块 构建配置; 类别 infra; 类型 infrastructure; 符号 get_cache_from_rocm_rust, get_cache_to_rocm_rust, ROCM_RUST_CACHE_TO_MODE) : HCL 配置文件, 定义 Rust 缓存导入 / 导出函数, 与 Shell 脚本配合生成正确的 --cache-from/to 参数。

关键符号: uses_rocm_rust_cache, compute_rocm_rust_content_hash, compute_rocm_rust_content_hash_if_needed, get_cache_from_rocm_rust, get_cache_to_rocm_rust

关键源码片段

docker/Dockerfile.rocm

Docker 构建定义, 重组 Rust 阶段以分离输入, 实现精确缓存依赖。

```
# Rust/protoc toolchain inputs——独立于源码, 避免源码变更影响工具链缓存
FROM scratch AS rust_toolchain_input_0
COPY rust-toolchain.toml /rust-toolchain-input/vllm/rust-toolchain.toml
COPY tools/install_protoc.sh /rust-toolchain-input/vllm/tools/install_protoc.sh

FROM base AS rust_toolchain_input_1
ARG VLLM_REPO
ARG VLLM_BRANCH
RUN git clone --no-checkout --filter=blob:none ${VLLM_REPO} /rust-toolchain-input/vllm \
    && cd /rust-toolchain-input/vllm \
    && git fetch -v --prune -- origin ${VLLM_BRANCH} \
    && git sparse-checkout init --no-cone \
    && git sparse-checkout set \
        rust-toolchain.toml \
        tools/install_protoc.sh \
    && git checkout FETCH_HEAD

FROM rust_toolchain_input_${REMOTE_VLLM} AS rust-toolchain-input

# Rust build inputs——仅包含编译 Rust 前端所需的文件
FROM scratch AS rust_input_0
COPY requirements/build/rust.txt /rust-input/vllm/requirements/build/rust.txt
COPY rust/Cargo.lock rust/Cargo.toml /rust-input/vllm/rust/
COPY rust/proto /rust-input/vllm/rust/proto
COPY rust/src /rust-input/vllm/rust/src
COPY rust-toolchain.toml /rust-input/vllm/rust-toolchain.toml
COPY tools/build_rust.py /rust-input/vllm/tools/build_rust.py
COPY build_rust.sh /rust-input/vllm/build_rust.sh

FROM base AS rust_input_1
ARG VLLM_REPO
ARG VLLM_BRANCH
RUN git clone --no-checkout --filter=blob:none ${VLLM_REPO} /rust-input/vllm \
    && cd /rust-input/vllm \
    && git fetch -v --prune -- origin ${VLLM_BRANCH} \
```

```

&& git sparse-checkout init --no-cone \
&& git sparse-checkout set \
    requirements/build/rust.txt \
    rust/Cargo.lock \
    rust/Cargo.toml \
    rust/proto/** \
    rust/src/** \
    rust-toolchain.toml \
    tools/build_rust.py \
    build_rust.sh \
&& git checkout FETCH_HEAD

```

FROM rust_input_\${REMOTE_VLLM} AS rust-input

docker/ci-rocm.hcl

HCL 配置文件，定义 Rust 缓存导入 / 导出函数，与 Shell 脚本配合生成正确的 --cache-from/to 参数。

从注册表拉取 Rust 构建缓存（精确提交、父提交、合并基、分支标签）

```

function "get_cache_from_rocm_rust" {
    params = []
    result = compact([
        BUILDKITE_COMMIT != "" ? "type=registry,ref=${DOCKERHUB_CACHE_REPO}:rust-rocm-
        ${BUILDKITE_COMMIT}" : "",
        PARENT_COMMIT != "" ? "type=registry,ref=${DOCKERHUB_CACHE_REPO}:rust-rocm-
        ${PARENT_COMMIT}" : "",
        VLLM_MERGE_BASE_COMMIT != "" ? "type=registry,ref=${DOCKERHUB_CACHE_REPO}:rust-
        rocm-${VLLM_MERGE_BASE_COMMIT}" : "",
        ROCM_CACHE_BRANCH_TAG != "" ? "type=registry,ref=${DOCKERHUB_CACHE_REPO}:rust-
        rocm-branch-${ROCM_CACHE_BRANCH_TAG}" : "",
        ROCM_CACHE_UPSTREAM_BRANCH_TAG != "" ? "type=registry,ref=${DOCKERHUB_CACHE_
        REPO}:rust-rocm-branch-${ROCM_CACHE_UPSTREAM_BRANCH_TAG}" : "",
    ])
}

```

导出 Rust 构建缓存到注册表（精确提交和分支标签，模式由变量控制）

```

function "get_cache_to_rocm_rust" {
    params = []
    result = compact([
        BUILDKITE_COMMIT != "" ? "type=registry,ref=${DOCKERHUB_CACHE_REPO}:rust-rocm-
        ${BUILDKITE_COMMIT},mode=${ROCM_RUST_CACHE_TO_MODE}" : "",
        ROCM_CACHE_BRANCH_TAG != "" ? "type=registry,ref=${DOCKERHUB_CACHE_REPO}:rust-
        rocm-branch-${ROCM_CACHE_BRANCH_TAG},mode=${ROCM_RUST_CACHE_TO_MODE}" : "",
    ])
}

```

评论区精华

- @tjtanaa 询问 AMD CI 是否使用 REMOTE_VLLM=1，作者确认使用但指出历史不清晰。该参数控制从远程仓库克隆代码，影响缓存输入路径。
- @depthfirst-app[bot] 建议对 `curl ... | sh` 远程脚本安装增加校验和验证，降低安全风险。作者未回应此建议。
- AMD CI 是否使用 REMOTE_VLLM=1 (question): AndreasKaratzas 确认 AMD CI 确实使用 REMOTE_VLLM=1，但指出历史不明确。
- 远程安装脚本安全风险 (security): 未在 PR 中解决，但严重性标记为 LOW。

风险与影响

- 风险：
 - 缓存逻辑复杂，新增多个阶段和哈希计算，可能引入缓存未命中或构建失败的风险，尤其是 REMOTE_VLLM=1 的网络依赖。
 - 安全建议未采纳：rustup 安装脚本直接管道执行，理论上存在被篡改风险，但 CI 环境通常可控。
 - 影响范围仅限 ROCm 后端 CI，其他平台无影响。
- 影响：
 - 用户：降低 ROCm Docker 镜像构建时间，减少 CI 资源消耗。
 - 系统：通过内容哈希缓存避免全量 Rust 重编译，提升构建效率。
 - 团队：后续维护需注意 Dockerfile.rocm 中阶段命名和缓存标签的兼容性。
 - 风险标记：远程脚本无校验和，REMOTE_VLLM 依赖网络稳定性，缓存阶段命名硬编码

关联脉络

- PR #48222 [CI][Rust Frontend] Pin cargo tool versions: 同属 Rust 相关 CI 基础设施改进，该 PR 固定工具版本，此 PR 优化构建缓存。