

PR #33597 完整报告

sgl-project/sglang

[CI] Extract `download-rust-ext` and give every install step a cache fallback

合并时间: 2026-08-05 06:33

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/33597>

执行摘要

- 一句话: 提取 rust-ext 下载操作, CI 安装回退到缓存
- 推荐动作: 值得精读, 特别是 download-rust-ext 的“artifact 优先、cache 兜底”设计, 以及用 outputs.hit 门控工具链安装的思路。对维护大型 GitHub Actions 的团队有参考价值, 可迁移到其他需要“预构建产物 + 缓存回退”的场景。

功能与动机

PR body 指出 `_pr-test-rust-ext-build.yml` 发布的 artifact 只有 1 天签发, 过期后任何重跑都会在安装期间重新编译全部 Rust 扩展; `rerun-test.yml` 因为是 `workflow_dispatch`, 运行中没有 `rust-ext-build` 作业, 完全读不到 artifact, 只能每次冷编译。作者希望让过期 artifact 不再导致冷 cargo build, 并把可淘汰的 cache 作为第二层来源。

实现拆解

实现分 5 步:

1. 新建复合操作 `.github/actions/download-rust-ext/action.yml`, 优先从 artifact 读取, 失败后安装 `zstd` 并回退 `actions/cache/restore@v4`, 命中时通过 `GITHUB_ENV` 写入 `SGLANG_BUILD_RUST_EXTS=none`, 并通过 `outputs.hit` 暴露命中状态。
2. 收敛调用点: `_pr-test-stage.yml`, `_pr-test-stage-cpu.yml`, `pr-test-jit-kernel.yml`, `pr-test-multimodal-gen.yml`, `pr-test-sgl-kernel.yml` 中 16 处内联步骤替换为 2-4 行操作引用, 删除重复的 `continue-on-error` 与步骤级 `env`。
3. 调整 CPU 阶段门控: `_pr-test-stage-cpu.yml` 的 `install_rust_protoc.sh` 与 `Swatinem/rust-cache` 改用 `outputs.hit != 'true'` 才执行, 命中时同时跳过工具链安装和缓存恢复。
4. 接入 `rerun-test.yml`: 三个作业 (`cuda` / `multimodal_gen` / `cpu`) 都使用操作, `cpu` 作业在托管 runner 上原本每次冷编译, 现在可命中缓存并跳过工具链。
5. 处理 `aarch64` 例外: `pr-test.yml` 用显式 `skip_prebuilt_rust_ext: true` 替代空 artifact 名, 并抽取 `scripts/ci/utils/ensure_zstd.sh` 统一 `zstd` 安装。

关键文件:

- `.github/actions/download-rust-ext/action.yml` (模块 CI 操作; 类别 `infra`; 类型 `infrastructure`): 新增复合操作, 统一 artifact + cache 两条获取路径, 是本次重构的核

心。

- `.github/workflows/pr-test-multimodal-gen.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : 多模态生成测试工作流, 6 个 job 的重复下载逻辑全部折叠, 集中体现调用点收敛。
- `.github/workflows/pr-test-jit-kernel.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : jit-kernel 专项工作流, 同样收敛 4 处重复逻辑, 保证缓存回退覆盖。
- `.github/workflows/pr-test-sgl-kernel.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : sgl-kernel 测试工作流, 也是核心调用方之一, 折叠后维护成本下降。
- `.github/workflows/_pr-test-rust-ext-build.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : 产物生产端, 需要保证保存的 cache 条目能被读者用 zstd 读到。
- `.github/workflows/_pr-test-stage-cpu.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : CPU 阶段按命中状态跳过 protoc + Rust 工具链, 是本 PR 的行为变化点之一。
- `.github/workflows/_pr-test-stage.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : 通用 stage 新增 skip_prebuilt_rust_ext 输入, 显式处理 aarch64 例外。
- `scripts/ci/utls/ensure_zstd.sh` (模块 CI 脚本; 类别 infra; 类型 infrastructure) : 新增脚本, 统一 cache 读写两侧的 zstd 安装, 防止压缩工具差异导致缓存 miss。
- `.github/workflows/rerun-test.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : workflow_dispatch 的重跑入口, 从无法读 artifact 变为可命中 cache, cpu 作业跳过工具链安装, 收益最大。
- `.github/workflows/pr-test.yml` (模块 CI 工作流; 类别 infra; 类型 infrastructure) : 顶层工作流, 将 gb300 阶段的 aarch64 例外改为显式 skip 输入。

关键符号: download-rust-ext, ensure_zstd.sh

评论区精华

本 PR 无专人 review 评论; 唯一的交互来自 GitHub Actions bot 的 rerun-test 结果确认 (test_quant_config_parsing.py 与 test_cuda_wrapper.py 均通过)。作者通过 /tag-and-rerun-ci 和 /rerun-test 触发了重跑, 没有公开的设计争议。

- 暂无高价值评论线程

风险与影响

- 风险: 主要风险集中在四点: 1) aarch64 阶段: cache 键不含架构, 若新增调用点未设 skip_prebuilt_rust_ext 会拿到 x86_64 模块; 2) zstd 依赖: 自托管 runner 缺 zstd 时缓存静默 miss, ensure_zstd.sh 安装失败仅告警, 行为退回冷编译但不更差; 3) SGLANG_BUILD_RUST_EXTs 从 step 级 env 移到 GITHUB_ENV, 作用域扩大, 未来新读者需注意; 4) 仓库 cache 已达 10 GB 上限, 缓存可能淘汰, 但 artifact 优先能兜底。
- 影响: 影响的都是 CI 基础设施: 所有导入 rust-ext 的测试工作流 (jit-kernel、sgl-kernel、multimodal-gen、基础 stage、rerun-test) 都会使用新操作, 行为一致性提升, 重复代码显著减少。开发者的直接收益是重跑过期 PR 或 workflow_dispatch 时

不再等待 cargo 全量编译，尤其是 cpu 作业托管 runner 的冷启动。对运行时代码无影响，风险集中在 workflow YAML 回归，但旧逻辑未删除，失败基本可回退。

- 风险标记：缓存键不区分架构，依赖 zstd 压缩工具，缓存易被淘汰，GITHUB_ENV 变量作用域变化

关联脉络

- 暂无明显关联 PR