

PR #2538 完整报告

radixark/miles

release: miles version release workflow

合并时间: 2026-08-15 10:57

原文链接: <http://prhub.com.cn/radixark/miles/pull/2538>

执行摘要

- 一句话: 新增 CI 门控的版本发布工作流, 冻结依赖三元组并发布官方镜像。
- 推荐动作: 值得精读。本 PR 展示了多个高价值设计决策: 用 commit status 做跨工作流门控、cadence 覆盖隔离 release 与 nightly 基线、retag 规避镜像清理周期、cherry-pick 与镜像层一致性约束。发布维护者应重点阅读 docs/ci/04-release.md 与 release-tag.yml 的 force 逃生门; 普通贡献者需要了解 bot-cherry-pick.yml 的限制。

功能与动机

PR body 明确说明: 官方发布必须保留通过 CI 的精确 Miles、SGLang、Megatron-LM 源码组合, 而此前 CI 无法针对任意 release ref 运行全量发布范围, 也无法在分支切割、hotfix、打 tag、镜像发布之间携带冻结的三元组, 维护者缺少一条可复现、受支持的发布路径。

实现拆解

1. CI 策略层: 新增 release cadence 与 cadence 覆盖

- tests/ci/ci_policy.py: 新增 RELEASE_CADENCE 并纳入 CI_CADENCES; resolve_policy 中 release 与 weekly 一样全范围、admit_nightly_tests=True、bypass_fastfail=True, 但 write_baseline 保持 False (冻结 SHA 的 release 运行写基线会污染 nightly 对比); resolve_workflow_inputs 新增 cadence_override 参数并优先于触发器推断, 避免被调用工作流继承调用方 event_name 时静默降级为 regular 范围。
- .github/workflows/pr-test.yml: 新增 workflow_call 输入 ref、cadence (默认 release)、image_tag; resolve-ci-policy 任务故意不 checkout inputs.ref (防 CodeQL 缓存投毒); concurrency group 改为字面量前缀 pr-test- 并加入 inputs.ref, 解决被调用时 github.workflow 解析为调用方名称导致 CUDA/ROCM 互相取消的问题; 各 stage 透传 ref。
- pr-test-rocm.yml 与可复用 _run-ci*.yml 同步透传 ref, 保证 release 分支 smoke 也测试正确 commit。

关键文件:

- .github/workflows/release-branch-cut.yml (模块 发布编排; 类别 infra; 类型 infrastructure): 发布流程的编排入口: 切分支、冻结依赖、retag 镜像、调度全量 CI、打 commit status。

- `.github/workflows/release-tag.yml` (模块 标签门控; 类别 `infra`; 类型 `infrastructure`) : 发布门控核心: 校验 `setup.py` 版本、要求 `release-ci commit status` 为 `success`, 创建 `tag` 并触发镜像构建。
- `.github/workflows/release-docker.yml` (模块 镜像发布; 类别 `infra`; 类型 `infrastructure`) : 官方镜像构建与发布: 从 `release-lock.json` 读取 `SGLang/Megatron SHA` 构建 `cu13/cu12` 镜像。
- `tests/ci/ci_policy.py` (模块 CI 策略; 类别 `test`; 类型 `core-logic`; 符号 `resolve_policy`, `resolve_workflow_inputs`, `RELEASE_CADENCE`) : CI 策略核心: 新增 `release cadence` 与 `cadence_override`, 保证 `release` 运行不写性能基线。
- `.github/workflows/bot-cherry-pick.yml` (模块 热修挑选; 类别 `infra`; 类型 `infrastructure`) : 热修复流程的关键约束: 拒绝镜像层文件改动, 保证冻结镜像与发布镜像一致性。
- `.github/scripts/release/write_release_lock.py` (模块 依赖冻结; 类别 `infra`; 类型 `data-contract`; 符号 `main`) : 定义 `release-lock.json` 的 `schema` 与写入逻辑, 是依赖冻结的单一事实来源。
- `.github/workflows/pr-test.yml` (模块 CI 编排; 类别 `infra`; 类型 `infrastructure`) : PR CI 主工作流被改为支持 `workflow_call` 与 `release cadence`, 变更涉及 `concurrency`、输入透传等核心机制。
- `docs/ci/04-release.md` (模块 发布文档; 类别 `docs`; 类型 `documentation`) : 发布流程的操作手册, 维护者按此从版本 `bump` 走到镜像验证。
- `tests/ci/test/test_run_suite.py` (模块 策略测试; 类别 `test`; 类型 `test-coverage`) : CI 策略锁测试: 更新 `concurrency` 表达式并覆盖 `release cadence` 的语义。
- `.github/scripts/release/bump_miles_version.py` (模块 版本脚本; 类别 `infra`; 类型 `core-logic`; 符号 `main`) : `setup.py` 版本 `bump` 脚本, 版本号与 `tag` 一致性的第一道校验。
- `.github/workflows/bot-bump-miles-version.yml` (模块 版本提交; 类别 `infra`; 类型 `infrastructure`) : 自动化版本 `bump` 与开 PR 的机器人工作流。

关键符号: `resolve_policy`, `resolve_workflow_inputs`, `strip_run_ci_prefix`, `write_release_lock.main`, `bump_miles_version.main`

关键源码片段

`tests/ci/ci_policy.py`

CI 策略核心: 新增 `release cadence` 与 `cadence_override`, 保证 `release` 运行不写性能基线。

```
# release 与 weekly 同范围, 但绝不写性能基线
RELEASE_CADENCE = "release"
CI_CADENCES = frozenset({REGULAR_CADENCE, NIGHTLY_CADENCE, WEEKLY_CADENCE,
RELEASE_CADENCE})
```

```
def resolve_policy(cadence: str, raw_labels: set[str]) -> RunPolicy:
    """根据显式 cadence 与 raw labels 解析选择与 fast-fail 行为。"""
    if cadence not in CI_CADENCES:
        raise ValueError(f"Unknown CI cadence {cadence!r}")
```

```

if "nightly" in raw_labels and cadence != NIGHTLY_CADENCE:
    raise ValueError("The nightly workflow label requires cadence='nightly'")

requested = strip_run_ci_prefix(raw_labels) & set(KNOWN_LABELS)
# weekly 与 release 都包含全部注册标签; release 仅在不写基线这点上不同
if "run-ci-all" in raw_labels or cadence in {WEEKLY_CADENCE, RELEASE_CADENCE}:
    scope = set(KNOWN_LABELS)
elif cadence == NIGHTLY_CADENCE:
    scope = set(KNOWN_LABELS) - {"long", "ft-long"}
elif "run-ci-image" in raw_labels:
    scope = set(KNOWN_LABELS) - {"long", "ft-short", "ft-long"}
else:
    scope = set()
full_cadences = {NIGHTLY_CADENCE, WEEKLY_CADENCE, RELEASE_CADENCE}
return RunPolicy(
    cadence=cadence,
    include_labels=frozenset(scope | requested),
    admit_nightly_tests=cadence in full_cadences,
    bypass_fastfail=cadence in full_cadences or "bypass-fastfail" in raw_labels,
    # 冻结 SHA 的 release 运行写基线会污染 nightly 对比
    write_baseline=cadence in {NIGHTLY_CADENCE, WEEKLY_CADENCE},
)

```

```

def resolve_workflow_inputs(
    event_name: str, schedule: str, pr_labels_json: str, cadence_override: str = ""
) -> WorkflowPolicy:
    """适配 GitHub 触发器事实为稳定策略输出。

```

`cadence\_override` 显式携带 workflow_call 的 cadence (如 release 分支切割请求
 全量 release 运行), 必须优先于触发器推断: 被调用的工作流继承调用方的
 event_name, 若按触发器推断会把 release 运行静默降级为 regular 范围。

```

"""
if cadence_override:
    cadence, raw_labels = cadence_override, ()
elif event_name == "pull_request":
    raw_labels = _canonical_pr_labels(pr_labels_json)
    cadence = NIGHTLY_CADENCE if "nightly" in raw_labels else REGULAR_CADENCE
elif event_name == "schedule":
    cadence, raw_labels = SCHEDULE_POLICIES[schedule]
elif event_name == "workflow_dispatch":
    cadence, raw_labels = REGULAR_CADENCE, ()
else:
    raise ValueError(f"Unsupported PR Test trigger: {event_name}")
run_policy = resolve_policy(cadence, set(raw_labels))
return WorkflowPolicy(
    cadence=cadence,
    raw_labels=raw_labels,
    bypass_fastfail=run_policy.bypass_fastfail,

```

)

评论区精华

三条核心 review 讨论全部围绕发布安全性与可复现性：

1. CodeQL bot 指出 release-docker.yml 未显式限制 GITHUB_TOKEN 权限，最终补上 permissions: contents: read。
 2. guapisolo 的 P1 指出 release-tag.yml 用 run 创建时间判断 CI 新旧会误拒首次 cut run (run 创建早于 lockfile commit)，最终改为 release-branch-cut.yml 最后通过 finalizer 在 tested SHA 上打 release-ci commit status，release-tag 改为校验该 status。
 3. guapisolo 的 P1 指出 workflow_call 继承 caller 事件导致 docker-paths 不识别 Docker 变更，CI 会用旧冻结镜像而发布构建新镜像，最终通过 bot-cherry-pick.yml 拒绝所有触碰镜像层文件的 cherry-pick 来闭环。
- release-docker.yml 缺少显式 permissions (security): 已在工作流顶部补充显式 permissions: contents: read, guapisolo 在最终审批中再次提醒 'need handle permission issue'。
 - release-tag 门控不能用 run 创建时间判断 (correctness): 改为 release-branch-cut 的 finalizer 在 tested SHA 上打 release-ci commit status, release-tag 检查该 status, 彻底消除时间推断问题。
 - Docker 热修复后 CI 镜像与发布镜像不一致 (correctness): 在 bot-cherry-pick.yml 中拒绝所有触碰镜像层文件的提交, requirements.txt 例外; 镜像层修复必须走新版本。
 - 最终审批中的权限处理提醒 (security): release-docker.yml 补充 permissions: contents: read 后关闭。

风险与影响

- 风险:
 1. release-tag.yml 的门控完全依赖 release-ci commit status: 若 finalizer 未打上或 status 被覆盖, 会阻塞或误放行 tag; force=true 是设计好的审计逃生门, 但存在滥用风险。
 2. release-docker.yml (PR body 已指出) 手工 workflow_dispatch 时 version 与 ref 不交叉校验, 可能构建出与 tag 不一致的镜像。
 3. release-branch-cut.yml 通过 retag 规避 docker-build 的 dev 标签清理, 但依赖 Docker Hub API 与 buildx 的可用性; 若 dev 镜像 tag 规则变化, release 镜像可能找不到。
 4. bot-cherry-pick.yml 只拒绝 docker/ 下的镜像层文件, requirements.txt 等运行时依赖变更仍可 cherry-pick, 未来若构建引入新的镜像层来源需要同步更新黑名单。
 5. concurrency 字面量前缀依赖所有调用方保持命名一致, 新增可复用工作流时容易踩坑。
 - 影响: 对维护者: 发布路径从手工操作变为可审计、可重复的 CI 流程, 分支切割、CI 验证、打 tag、镜像发布之间有明确门控与证据链。对开发者: hotfix 提交策略受限 (镜像层改动只能走新版本), cherry-pick 流程被机器人接管。对 CI 资源: release cadence 复用 weekly 全量范围, 每次发布触发完整 CUDA/ROCm 套件, 资源开销大但

仅在发布时发生。对运行时与训练代码零影响。 - 风险标记：门控依赖 commit status, 镜像层 hotfix 受限，手工 dispatch 版本 /ref 不校验，concurrency 字面量前缀易失效，release cadence 资源消耗大

关联脉络

- PR #2564 release: bump miles version to 0.1.0: 首个通过本发布流程落地的版本 bump，验证 bot-bump-miles-version.yml 产出的 PR 形态。
- PR #2499 feat(ci): add weekly full-suite cadence: 引入 cadence 策略与 CI 套件编排，本 PR 在其基础上新增 release cadence 并复用其策略解析框架。
- PR #2480 [AMD CI] Enable verified ROCm tests: ROCm CI 套件在本 PR 中被接入 release 流程，pr-test-rocm.yml 透传 ref 并使用 release cadence。