

PR #33498 完整报告

sgl-project/sglang

Build and release sgl-deep-ep wheels

合并时间: 2026-08-06 17:07

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/33498>

执行摘要

- 一句话: 新增 sgl-deep-ep wheel 构建与发布流水线
- 推荐动作: 该 PR 值得发布负责人和 DevOps 精读, 重点学习多 CUDA 版本、多架构 wheel 的构建与发布策略 (auditwheel 排除规则、PyPI 本地版本剥离、PEP 503 索引维护)。普通开发者只需了解 sgl-deep-ep 的安装方式。在合并前应确认 DeepEP#3 已合并、secrets 已配置, 并在真实环境跑一次 0.1.0rc0 验证。

功能与动机

PR body 明确指出: 为 sgl-deep-ep 二进制发行版添加发布流水线, 让 CUDA 13 构建可通过 `pip install sgl-deep-ep` 安装, CUDA 12.9 构建通过 SGLang wheel 索引发布。关联 issue (sgl-project/DeepEP#3) 进一步说明需要在独立分支上维护共享的 sgl_deep_ep 打包 overlay, 保持三个实现分支无重复打包文件。

实现拆解

1. 构建编排脚本 (scripts/build_sgl_deepest.sh): 将原构建脚本改造为 Docker 编排器, 接收 Python 版本、CUDA 版本、DeepEP 源码路径、打包 overlay 路径和架构参数。内部校验输入合法性、选择对应 manylinux 基础镜像 (x86_64 用 pytorch/manylinux2_28-builder, aarch64 用 pytorch/manylinuxaarch64-builder), 构建并运行容器, 在容器内调用 overlay 的构建脚本, 再通过 auditwheel 修复为 manylinux_2_28 wheel, 并为 CUDA 13 额外生成去掉本地版本号的 PyPI 专用 wheel。
2. 构建容器 (docker/sgl-deep-ep.Dockerfile): 基于 PyTorch manylinux 镜像, 安装 RDMA 依赖 (libibverbs、rdma-core、libfabric 等)、GDRCopy 2.5.1 用户态库, 并配置 CUDA stub 链接。使用 BuildKit 缓存加速 pip 安装, 固定 PyTorch 2.11.0。
3. 发布工作流 (.github/workflows/release-whl-deepest.yml): 定义手工触发的 workflow_dispatch, 输入 version、target (all/cu129/cu130)、packaging-ref (默认 sgl-deepest-packaging)。按矩阵构建 cu129 (Python 3.10/3.12 x x86_64/aarch64) 和 cu130 (Python 3.10-3.13 x x86_64/aarch64), 对应源码分支为 sgl-deepest-x86、sgl-deepest-cu12-arm、sgl-deepest-arm。构建产物上传至 sgl-project/whl 的 GitHub Release, 并克隆 gh-pages 分支更新 PEP 503 索引; cu130 wheel 同时去除 +cu130 标签后上传 PyPI。
4. 索引更新器 (scripts/update_deepest_whl_index.py): 实现幂等的 PEP 503 索引更新, 支持 cu129/cu130 两个 CUDA 版本, 生成带 SHA256 的下载链接, 并确保根索引包含

sgl-deep-ep 子目录入口。

5. 配套说明：PR 未包含测试或文档（文档改动已在评审中移除）。验证以静态检查为主（shellcheck、bash -n、预提交、字节编译等），真实 wheel 编译和 GPU/ 传输执行推迟到下一阶段。

关键文件：

- `scripts/update_deepep_whl_index.py` (模块 索引工具; 类别 `source`; 类型 `dependency-wiring`; 符号 `_sha256`, `_ensure_root_link`, `update_wheel_index`, `main`) : 核心的 PEP 503 索引更新逻辑, 是发布流水线的关键组成部分, 决定了用户能否通过 `wheel` 索引正确发现并下载不同 `CUDA` 版本的 `sgl-deep-ep`。
- `.github/workflows/release-whl-deepep.yml` (模块 发布流水线; 类别 `infra`; 类型 `infrastructure`) : 发布工作流是流水线的中枢, 定义了构建矩阵、发布目标、索引更新和 `PyPI` 发布的全过程。
- `scripts/build_sgl_deepep.sh` (模块 构建脚本; 类别 `other`; 类型 `core-logic`) : 构建脚本是整个流程的编排核心, 负责参数校验、`Docker` 镜像构建与运行、`auditwheel` 修复以及 `cu130` `PyPI` 版本剥离。
- `docker/sgl-deep-ep.Dockerfile` (模块 构建镜像; 类别 `infra`; 类型 `infrastructure`) : 容器镜像定义构建环境, 包括 `RDMA` 依赖、`GDRCopy` 和 `CUDA` 环境配置, 是跨架构一致构建的基础。

关键符号: `update_wheel_index`, `main`, `_sha256`, `_ensure_root_link`

关键源码片段

scripts/update_deepest_whl_index.py

核心的 PEP 503 索引更新逻辑，是发布流水线的关键组成部分，决定了用户能否通过 wheel 索引正确发现并下载不同 CUDA 版本的 sgl-deep-ep。

"""PEP 503 索引更新: 为 sqlalchemy-deep-ep 发布 wheel 生成并维护索引页面."""

```
import hashlib
import pathlib
import re
```

```
SUPPORTED_CUDA_VERSIONS = ("129", "130")
WHEEL_PATTERN = re.compile(
    r"^sgl_deep_ep-(?P<version>[0-9][^-]*)-[^-]+-[^-]+\.[^.]$")
ANCHOR_PATTERN = re.compile(r'^<a href="[^"]+">(P<filename>[^<+>+</a><br>$')
```

```
def _sha256(path: pathlib.Path) -> str:
    """分块计算 wheel 文件的 SHA256 摘要，避免一次性读入大文件。"""
    digest = hashlib.sha256()
    with path.open("rb") as wheel_file:
        for chunk in iter(lambda: wheel_file.read(1024 * 1024), b""):
```

```
        digest.update(chunk)
    return digest.hexdigest()
```

```
def _ensure_root_link(cuda_root: pathlib.Path) -> None:
    """在 cuXXX 根索引中添加指向 sgl-deep-ep 子目录的链接，幂等地追加。"""
    root_index = cuda_root / "index.html"
    lines = root_index.read_text().splitlines() if root_index.exists() else []
    doctype = [line for line in lines if line.startswith("<!DOCTYPE")]
    anchors = [line for line in lines if line.startswith("<a ")]
    link = '<a href="sgl-deep-ep/">sgl-deep-ep</a>'
    if link not in anchors:
        anchors.append(link)
    content = [*doctype or ["<!DOCTYPE html>"], *sorted(set(anchors))]
    root_index.write_text("\n".join(content) + "\n")
```

```
def update_wheel_index(
    cuda_version: str, wheel_dir: pathlib.Path, repository: pathlib.Path
) -> None:
    """更新指定 CUDA 版本的 PEP 503 索引页。
```

只处理带对应 +cuXXX 本地版本号的 wheel，并为每个 wheel 生成
GitHub Release 下载链接与 SHA256 校验值。

"""

```
if cuda_version not in SUPPORTED_CUDA_VERSIONS:
    raise ValueError(f"Unsupported CUDA version: {cuda_version}")
```

```
cuda_root = repository / f"cu{cuda_version}"
index_dir = cuda_root / "sgl-deep-ep"
index_dir.mkdir(exist_ok=True, parents=True)
_ensure_root_link(cuda_root)
```

```
# 读取现有条目，保证索引可重复更新（幂等）
index_path = index_dir / "index.html"
entries = {}
if index_path.exists():
    for line in index_path.read_text().splitlines():
        match = ANCHOR_PATTERN.match(line)
        if match:
            entries[match.group("filename")] = line
```

```
# 为每个匹配的 wheel 生成带 SHA256 的下载 URL
suffix = f"+cu{cuda_version}"
release_base = "https://github.com/sgl-project/whl/releases/download"
for path in sorted(wheel_dir.glob("*.whl")):
    match = WHEEL_PATTERN.match(path.name)
    if not match or suffix not in match.group("version"):
        continue
```

```

public_version = match.group("version").split("+", 1)[0]
url = f"{release_base}/v{public_version}/{path.name}#sha256={_sha256(path)}"
entries[path.name] = f'<a href="{url}">{path.name}</a><br>'

content = ["<!DOCTYPE html>", *(entries[name] for name in sorted(entries))]
index_path.write_text("\n".join(content) + "\n")

```

scripts/build_sgl_deep_ep.sh

构建脚本是整个流程的编排核心，负责参数校验、Docker 镜像构建与运行、auditwheel 修复以及 cu130 PyPI 版本剥离。

在构建容器内执行的命令：调用 overlay 构建脚本、repair wheel、生成 PyPI 版本

```

bash /packaging/build_sgl_deep_ep.sh \
    /deep /packaging "${raw_dir}" "${CUDA_VERSION}" "${ARCHITECTURE}"

```

使用 auditwheel 将 wheel 重打为 manylinux_2_28，并排除宿主提供的动态库

这些库（如 libcuda.so.1、libtorch.so）在运行时由用户环境提供，不应打入 wheel

```

auditwheel repair \
    --plat "manylinux_2_28_${ARCHITECTURE}" \
    --wheel-dir /output/dist \
    --exclude libcuda.so.1 \
    --exclude libcudart.so.12 \
    --exclude libcudart.so.13 \
    --exclude libtorch.so \
    --exclude libtorch_cpu.so \
    --exclude libtorch_cuda.so \
    --exclude libnccl.so.2 \
    --exclude libgdrapi.so.2 \
    "${raw_wheels[0]}"

```

CUDA 13 构建额外生成 PyPI 版本：去掉 +cu130 本地版本号，改写 METADATA 并重打包

```

if [[ "${CUDA_TAG}" == cu130 ]]; then
    tagged_wheels=(/output/dist/sgl_deep_ep-*+cu130-*.whl)
    if [[ ${#tagged_wheels[@]} -ne 1 ]]; then
        echo "Expected exactly one CUDA 13 wheel, found ${#tagged_wheels[@]}" >&2
        exit 1
    fi
    unpack_root="$(mktemp -d -t sgl-deep-ep-pypi.XXXXXX)"
    python -m wheel unpack "${tagged_wheels[0]}" --dest "${unpack_root}"
    unpacked="$(find "${unpack_root}" -mindepth 1 -maxdepth 1 -type d | head -1)"
    dist_info="$(find "${unpacked}" -maxdepth 1 -type d -name "*.dist-info" | head -1)"
    metadata="${dist_info}/METADATA"
    original_version="$(sed -n "s/^Version:[[:space:]]*//p" "${metadata}" | head -1)"
    public_version="${original_version%+cu130}"
    if [[ "${original_version}" == "${public_version}" ]]; then
        echo "CUDA 13 wheel metadata lacks the +cu130 local version" >&2
        exit 1
    fi
    # 改写 METADATA 中的 Version 行，并重命名 dist-info 目录以匹配新版本

```

```
sed -i "s/^Version:.* /Version: ${public_version}/" "${metadata}"
old_dist_info="$(basename "${dist_info}")"
new_dist_info="${old_dist_info}/${original_version}/${public_version}"
mv "${dist_info}" "$(dirname "${dist_info}")/${new_dist_info}"
python -m wheel pack "${unpacked}" --dest-dir /output/dist-pypi
fi
```

评论区精华

评审中作者 (Fridge003) 提出了两条自审意见:

- 针对 docs_new/docs/developer_guide/release_sgl_deep_ep.mdx: 明确“No need to change docs folder in this PR”, 最终提交中移除了文档改动, 将 PR 范围收敛为工作流、Dockerfile、构建脚本和索引更新器。
- 针对 .github/workflows/release-whl-deepep.yml: 将默认 packaging-ref 分支从 sgl-deepep-x86 改为 sgl-deepep-packaging, 确保共享 overlay 默认使用独立维护分支, 与 DeepEP#3 的设计一致。
- 移除文档改动 (documentation): 后续提交移除了文档文件, PR 收敛为工作流、Dockerfile、构建脚本和索引更新器。
- 默认 packaging-ref 分支 (design): 最终提交将默认值改为 sgl-deepep-packaging, 保证工作流默认使用共享打包 overlay。

风险与影响

- 风险:
 1. 依赖未合并的上游 PR: 工作流默认引用 sgl-deepep-packaging 分支, 该分支上的共享 overlay 由 sgl-project/DeepEP#3 提供, 若该 PR 未合并或分支不存在, 构建会失败。
 2. 真实构建未验证: PR 仅通过静态检查, 未实际编译 wheel。CUDA 13.0 与 aarch64 组合可能存在编译错误或运行时库缺失, 尤其是 GDRCopy、libfabric 等 RDMA 依赖的兼容性。
 3. secrets 依赖: 发布依赖 SGL_DEEP_EP_PYPI_TOKEN 和 GH_PAT_FOR_WHL_RELEASE 两个 secret, 若未配置, 发布步骤会失败。
 4. auditwheel 排除规则风险: build_sgl_deepep.sh 中排除了 libtorch.so、libnccl.so.2 等大量动态库, 若这些库在目标环境缺失, wheel 运行时可能链接失败。
 5. 发布竞态: 工作流设置了 concurrency 组 release-sgl-deep-ep 且 cancel-in-progress: false, 但多版本并发发布时, PEP 503 索引更新可能因 git 推送竞争产生不一致。- 影响: 对用户: CUDA 13 用户可直接 pip install sgl-deep-ep, CUDA 12.9 用户通过 sgl-project/whl 索引安装, 大幅简化 DeepEP 的安装步骤。对系统: 新增一套完整的发布基础设施, 包含 Docker 构建镜像、CI 工作流和索引更新工具, 后续维护成本提高。对团队: 需要维护三个 DeepEP 实现分支与共享打包 overlay 的同步, 发布流程依赖两个 secret, 且需按版本手动触发, 建议制定发布检查单。- 风险标记: 依赖未合并的上游 PR, 真实构建未验证, secrets 未配置风险, aarch64 兼容性风险, 发布竞态

关联脉络

- 暂无明显关联 PR