

PR #51159 完整报告

vllm-project/vllm

```
[ROCm] Defer `tilelang` import through its import `from vllm.tilelang_utils import tilelang` and  
relaxed `has_tilelang`
```

合并时间: 2026-08-14 02:12

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/51159>

执行摘要

- 一句话: ROCm 延迟 TileLang 导入, 修复 HIP 符号污染
- 推荐动作: 值得精读。设计上展示了如何在不引入 facade 的前提下用装饰器延迟 JIT, 以及如何在 import 检测里避免副作用; 对后续在 ROCm 上接入其他重依赖库有参考意义。建议关注两个 follow-up: tilelang/TVM 上游符号修复, 和 #51162 中 `_has_module` 的全面改造。

功能与动机

issue #51151 报告: PR #50879 之后, ROCm 上 `import tilelang` 会向全局进程符号表注入错误 / 损坏的 `hipMalloc/hipFree` (来自 `libhip_stub.so`), 导致 AITER 加载其 JIT 模块后出现分配与测试失败。本 PR 旨在从 vLLM 侧规避该问题——任何 ROCm 模块导入路径都不应再触发 tilelang 加载; 同时呼应 #51162, `_has_module` 这类探测函数不应真正导入模块。

实现拆解

1. 新增 `vllm/tilelang_utils/__init__.py`: 集中管理 `tilelang/tilelang.language` 的导入。CUDA 平台在模块导入时即校验并 eager 导入; ROCm 等其它平台先置 `None` 占位。`_ensure_tilelang_imported()` 在首次使用时把真正的模块绑定回全局;`_get_pass_configs()` 缓存按平台生成的 JIT pass 配置 (CUDA 额外加 `TL_PTXAS_REGISTER_USAGE_LEVEL=10`)。
2. 实现平台分叉的 `tilelang_jit` 装饰器: 非 ROCm 路径保持 `tilelang.jit(pass_configs=...)` 的 eager 装饰; ROCm 路径返回 `wrapper`, 在第一次调用时导入 `tilelang`、把 `tilelang` 与 `T` 重新注入到被装饰函数所在模块的 `__globals__` (kernel 函数体以无前缀 `T` 引用 DSL 符号), 再编译并缓存 `compiled_kernel`。
3. 重接 `vllm/model_executor/kernels/mhc/tilelang_kernels.py`: 删除原先的 `has_tilelang` 检查、直接 `import tilelang` 和模块级 `pass_configs`, 8 个 MHC kernel 装饰器统一改为 `@tilelang_jit`; `ENABLE_PDL` 逻辑保留。
4. 弱化 `has_tilelang` 副作用: `import_utils.py` 新增 `@cache _has_module_spec()` (仅 `find_spec`), `has_tilelang()` 改用它, 注释明确调用方必须在使用点自己懒加载。
5. 配套防护与测试: `tools/pre_commit/check_forbidden_imports.py` 新增 `tilelang` 禁止规则 (含正则用例); `vllm/utils/jit_monitor.py` 在 ROCm 上跳过 `_setup_tilelang_jit_hook()`; 新增 `tests/kernels/test_mhc_tilelang_jit.py` 覆盖 ROCm 懒加载与符号表不被

`libhip_stub.so` 劫持, `tests/jit_monitor/test_hooks.py` 对 `tilelang` 测试追加 ROCm skip 标记。

关键文件:

- `vllm/tilelang_utils/__init__.py` (模块 懒加载门控; 类别 `source`; 类型 `dependency-wiring`; 符号 `_ensure_tilelang_imported`, `_get_pass_configs`, `tilelang_jit`, `wrapper`): 新增的核心模块, 集中 `TileLang` 导入与 JIT 门控, 是 ROCm 懒加载方案的主干。
- `tests/kernels/test_mhc_tilelang_jit.py` (模块 内核测试; 类别 `test`; 类型 `test-coverage`; 符号 `_PassConfigKey`, `_install_tilelang_stub`, `jit`, `decorate`): 验证 CUDA eager / ROCm lazy 行为差异, 并用 `dlsym/dladdr` 守卫 HIP 符号表不被 `tilelang` 污染。
- `vllm/model_executor/kernels/mhc/tilelang_kernels.py` (模块 内核层; 类别 `source`; 类型 `data-contract`; 符号 `mhc_pre_big_fuse_tilelang`, `mhc_pre_big_fuse_with_norm_tilelang`, `mhc_pre_big_fuse_broadcast_with_norm_tilelang`, `mhc_fused_tilelang`): 唯一使用 `@tilelang.jit` 的生产代码; 通过切换装饰器彻底移除启动期 `tilelang import`。
- `vllm/utils/import_utils.py` (模块 导入工具; 类别 `source`; 类型 `core-logic`; 符号 `_has_module_spec`, `has_tilelang`): `has_tilelang` 从 `trial import` 降级为 `find_spec`, 消除探测函数的副作用, 呼应 `issue #51162`。
- `tools/pre_commit/check_forbidden_imports.py` (模块 提交钩子; 类别 `infra`; 类型 `configuration`): 新增 `tilelang` 禁止导入规则, 保证未来代码统一走 `vllm.tilelang_utils`。
- `vllm/utils/jit_monitor.py` (模块 监控模块; 类别 `source`; 类型 `dependency-wiring`; 符号 `activate`): 修复 `rasmith` 指出的残留导入路径: ROCm 上不再安装 `TileLang` JIT hook。
- `tests/jit_monitor/test_hooks.py` (模块 监控测试; 类别 `test`; 类型 `test-coverage`): 为 ROCm 上已禁用的 `tilelang` JIT 监控测试增加 skip 标记, 避免误报。
- `docs/assets/contributing/dockerfile-stages-dependency.png` (模块 文档资源; 类别 `other`; 类型 `core-logic`): 提交过程中被误改的 Dockerfile 阶段依赖图, 最终回滚, 无净变更。

关键符号: `tilelang_jit`, `_ensure_tilelang_imported`, `_get_pass_configs`, `_has_module_spec`, `has_tilelang`, `mhc_post_tilelang`, `test_tilelang_jit_decorator_is_lazy_only_on_rocm`, `test_deepseek_v4_import_and_jit_monitor_do_not_hijack_hip_symbols`

关键源码片段

`vllm/tilelang_utils/__init__.py`

新增的核心模块, 集中 `TileLang` 导入与 JIT 门控, 是 ROCm 懒加载方案的主干。

```
# vllm/tilelang_utils/__init__.py
# TileLang 的统一导入与 JIT 门控: CUDA 保持 eager, ROCm 延迟到首次调用。

from __future__ import annotations

import functools
```

```

from collections.abc import Callable
from functools import cache
from typing import TYPE_CHECKING, Any

from vllm.platforms import current_platform
from vllm.utils.import_utils import has_tilelang

# CUDA 平台在 import vllm.model_executor.kernels.mhc.tilelang_kernels 时就需要
# TileLang, 因此这里保持 eager 导入; ROCm 上先置空占位, 避免加载 tilelang 自带的
# 破损 TVM / HIP stub 符号 (见 issue #51151)。
if TYPE_CHECKING or current_platform.is_cuda():
    if not has_tilelang():
        raise ImportError(
            "tilelang is required for mhc but is not installed. Install it with "
            "`pip install tilelang`."
        )
    import tilelang
    import tilelang.language as T
else:
    tilelang = None # type: ignore[assignment]
    T = None # type: ignore[assignment]

def _ensure_tilelang_imported() -> None:
    """把 `tilelang` 与 `T` 绑定到本模块全局, 必要时才真正导入。

    在 ROCm 上该函数在第一次 kernel 调用时才执行, 从而把 tilelang 的
    import 副作用挡在启动路径之外。
    """
    global T, tilelang

    if tilelang is not None:
        return
    if not has_tilelang():
        raise ImportError(
            "tilelang is required for mhc but is not installed. Install it with "
            "`pip install tilelang`."
        )
    import tilelang as tilelang_module
    import tilelang.language as tilelang_language

    tilelang = tilelang_module
    T = tilelang_language

@cache
def _get_pass_configs() -> dict[Any, Any]:
    # 保证取配置前 TileLang 已就绪; CUDA 额外设置 PTXAS 寄存器用量
    _ensure_tilelang_imported()

```

```

pass_configs: dict[Any, Any] = {
    tilelang.PassConfigKey.TL_DISABLE_WARP_SPECIALIZED: True,
    tilelang.PassConfigKey.TL_DISABLE_TMA_LOWER: True,
}
if current_platform.is_cuda():
    pass_configs[tilelang.PassConfigKey.TL_PTXAS_REGISTER_USAGE_LEVEL] = 10
return pass_configs

```

```

def tilelang_jit(kernel_function: Callable[..., Any]) -> Callable[..., Any]:
    """`tilelang.jit` 的封装：ROCm 延迟装饰，CUDA 保持原语义。

```

TileLang 解析 kernel 函数体会引用无前缀全局名 `T`，因此延迟路径上编译前必须把 `T` / `tilelang` 重新注入到被装饰函数所在模块的 globals。

```

"""
if not current_platform.is_rocm():
    _ensure_tilelang_imported()
    return tilelang.jit(pass_configs=_get_pass_configs())(kernel_function)

```

```

compiled_kernel: Callable[..., Any] | None = None

```

```

@functools.wraps(kernel_function)
def wrapper(*args: Any, **kwargs: Any) -> Any:
    nonlocal compiled_kernel
    if compiled_kernel is None:
        _ensure_tilelang_imported()
        kernel_function.__globals__["tilelang"] = tilelang
        kernel_function.__globals__["T"] = T
        compiled_kernel = tilelang.jit(pass_configs=_get_pass_configs())(
            kernel_function
        )
    return compiled_kernel(*args, **kwargs)

return wrapper

```

tests/kernels/test_mhc_tilelang_jit.py

验证 CUDA eager / ROCm lazy 行为差异，并用 dlsym/dladdr 守卫 HIP 符号表不被 tilelang 污染。

```

# tests/kernels/test_mhc_tilelang_jit.py (节选，桩 + 懒加载用例)
import importlib
import sys
from types import ModuleType
from typing import Any

import pytest

from vllm.platforms import current_platform
from vllm.utils import import_utils

```

```

class _PassConfigKey:
    # 与真实 tilelang.PassConfigKey 对应的桩常量
    TL_DISABLE_WARP_SPECIALIZED = "disable_warp_specialized"
    TL_DISABLE_TMA_LOWER = "disable_tma_lower"
    TL_PTXAS_REGISTER_USAGE_LEVEL = "ptxas_register_usage_level"

def _install_tilelang_stub(monkeypatch: pytest.MonkeyPatch) -> dict[str, int]:
    # 用桩模块替换真实 tilelang，统计 jit 装饰与编译的次数
    calls = {"jit_decorate": 0, "compiled_call": 0}

    tilelang: Any = ModuleType("tilelang")

    def jit(**kwargs: Any) -> Any:
        def decorate(func: Any) -> Any:
            calls["jit_decorate"] += 1

            def compiled(*args: Any, **kw: Any) -> Any:
                calls["compiled_call"] += 1
                return func.__name__

            return compiled

        return decorate

    tilelang.PassConfigKey = _PassConfigKey
    tilelang.jit = jit

    monkeypatch.setattr(import_utils, "has_tilelang", lambda: True)
    monkeypatch.setitem(sys.modules, "tilelang", tilelang)
    monkeypatch.setitem(
        sys.modules, "tilelang.language", ModuleType("tilelang.language")
    )
    monkeypatch.delitem(sys.modules, "vllm.tilelang_utils", raising=False)

    return calls

def test_tilelang_jit_decorator_is_lazy_only_on_rocm(
    monkeypatch: pytest.MonkeyPatch,
) -> None:
    if not (current_platform.is_cuda() or current_platform.is_rocm()):
        pytest.skip("Test requires CUDA or ROCm")

    calls = _install_tilelang_stub(monkeypatch)
    module_name = "vllm.model_executor.kernels.mhc.tilelang_kernels"
    monkeypatch.delitem(sys.modules, module_name, raising=False)
    module = importlib.import_module(module_name)

```

```

# ROCm 下 import 模块不应触发 JIT 装饰; CUDA 下必须 eager 装饰
if current_platform.is_rocm():
    assert calls["jit_decorate"] == 0
else:
    assert calls["jit_decorate"] > 0

# 首次调用之后, ROCm 只装饰一次并进入 compiled 缓存
decorated_calls = calls["jit_decorate"]
assert module.mhc_post_tilelang() == "mhc_post_tilelang"
if current_platform.is_rocm():
    assert calls["jit_decorate"] == 1
else:
    assert calls["jit_decorate"] == decorated_calls
assert calls["compiled_call"] == 1

```

vllm/utils/import_utils.py

has_tilelang 从 trial import 降级为 find_spec, 消除探测函数的副作用, 呼应 issue #51162。

```

# vllm/utils/import_utils.py 中新增的轻量探测函数
@cache
def _has_module_spec(module_name: str) -> bool:
    """只解析 import spec, 不真正导入模块。

```

与 `\_has\_module` 不同, 它不做 trial import, 因此不会触发重模块的副作用 (例如 tilelang 注入破损的 HIP stub 符号), 代价是无法验证原生依赖 (共享库等) 是否真的可用。

```

"""
try:
    return importlib.util.find_spec(module_name) is not None
except Exception:
    return False

```

```

@cache
def has_tilelang() -> bool:
    """TileLang 是否可用: 仅检查 import spec。

```

tilelang 的导入开销大且可能有符号污染, 调用方必须在自己的使用点再懒加载, 而不是依赖本函数已经完成导入。

```

"""
if not _has_module_spec("tilelang"):
    return False
# ROCm 特有 guard, 延迟导入以免在 CUDA 上加载 rocm 相关代码
from vllm.platforms import current_platform

if current_platform.is_rocm():
    from vllm.platforms.rocm import on_gfx1250

# TODO: tilelang 支持 gfx1250 后放开

```

```
if on_gfx1250():
    return False
return True
```

评论区精华

- Isotr0py 建议参照 `triton_utils` 收敛导入: "How about making a `tilelang_utils` similar to `triton_utils`?" fxmarty-amd 采纳并进一步要求所有代码必须 `from vllm.tilelang_utils import tilelang`, 与 triton 规则对齐。
- Isotr0py 关心 DX: 希望用占位 facade 保留 `@tilelang.jit` 写法, fxmarty-amd 回应这样做需要 hacky 的 `_TileLangFacade`, 且本 PR 的目标更广——ROCm 启动期完全不 import `tilelang`; 最终以 `@tilelang.jit` 收场, Isotr0py 批准时留话: "Anyway, let's land this to fix the broken model first."
- rasmith 指出 `jit_monitor.py` 的 `_setup_tilelang_jit_hook` 仍会导入 `tilelang` 并导致 `test_online_quantization` 失败; fxmarty-amd 复现后补上 ROCm 门控, 并新增 "确认 `tilelang` 不被 import、符号不来自 `libhip_stub.so`" 的测试。
- tjtanaa 与 Fangzhou-Ai 确认: DeepSeek-V4 实际隐藏层大小 4096/7168 均走 AITER, `tilelang mHC` 路径在真实推理中不会被触发, 因此 ROCm 上跳过 `TileLang` 是安全的。
- 是否参照 `triton_utils` 引入统一 `tilelang` 导入模块 (design): 新增 `vllm.tilelang_utils` 模块, 并通过 pre-commit 禁止直接 import `tilelang`。
- 是否保留 `@tilelang.jit` 写法的 DX 权衡 (design): 以 `@tilelang.jit` 统一收口; Isotr0py 批准时表示先落地修复问题。
- `jit_monitor` 仍会导入 `tilelang` 导致失败 (correctness): ROCm 下 `activate()` 不再调用 `_setup_tilelang_jit_hook`; 增加测试确认 `tilelang` 未被 import 且 `hipFree` 来自 `libamdhip64.so`。
- DeepSeek-V4 是否真的会走 `tilelang mHC` 路径 (question): 真实推理不触发 `tilelang mHC`, ROCm 上跳过 `tilelang` 是安全的。

风险与影响

- 风险:
 - ROCm 首次 kernel 调用才编译, 可能出现运行时延迟或失败; 若 `tilelang` 本身损坏 (如 `gfx1250` 等), 错误从 import 期推迟到调用期, 更难定位; 测试仅覆盖 MI300/MI350。
 - `kernel_function.__globals__` 重绑定会改变被装饰函数模块的全局命名空间; 如果同一模块内其它代码在编译前使用 `T/tilelang`, 可能拿到 `None`。当前仅影响 `mhc/tilelang_kernels.py`。
 - `_get_pass_configs` 是 `@cache` 的, 首次调用发生在编译时; 若平台判断依赖运行时环境而非 import 时点, 配置可能与平台不符 (当前逻辑在 import 时判断, 风险低)。
 - CUDA/ROCm 行为分叉 (eager vs lazy), 同一份 kernel 代码在不同后端的行为差异虽有测试覆盖, 但其它调用点如果期望 import 后即可调用工厂函数, 行为可能改变。
 - `jit_monitor` 在 ROCm 上不再报告 `tilelang JIT`, 若未来真正启用 `tilelang mHC` 路径, 会失去运行时监控。

- pre-commit 新规则会拦截所有直接 import tilelang, 已有代码若有直接导入会触发 CI 失败, 需迁移。
- 影响:
 - ROCm (MI300/MI325/MI350) 用户: 修复由 tilelang 符号劫持导致的分配失败与 test_online 回归; 启动时间缩短 (跳过 tilelang 导入)。
 - DeepSeek-V4 MHC 路径: 实际推理仍走 AITER, tilelang 代码路径被推迟到调用层; 若 tilelang JIT 被真正触发, 单次首调编译延迟增加。
 - 开发侧: 新增统一的 tilelang 导入门控和 lint 规则, 后续 kernel 开发者须遵循 from vllm.tilelang_utils import tilelang, T。
 - 测试与 CI: 新增 ROCm 符号表守卫测试, tilelang 相关 jit_monitor 测试在 ROCm 上跳过; AMD CI 覆盖 MI300/MI350 验证。
 - 风险标记: ROCm 首调 JIT 延迟, 模块全局重绑定副作用, 临时关闭 JIT 监控, 平台行为分叉, 依赖上游修复

关联脉络

- 暂无明显关联 PR