

PR #46567 完整报告

vllm-project/vllm

Fix model info cache for package models

合并时间: 2026-06-29 17:17

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46567>

执行摘要

- 一句话: 修复包式模型注册的缓存失效问题
- 推荐动作: 该 PR 值得精读, 特别是 `_get_modelinfo_module_hash` 的设计决策。对于其他需要缓存包模块哈希的场景, 此模式可复用。

功能与动机

修复模型注册缓存键仅覆盖 `__init__.py`, 导致包式注册模型 (如 MiniMax-M3 PP 工作) 的子模块变更时, 缓存的 `capability` 元数据不会失效。这一问题在审查 #45810 时发现。

实现拆解

1. 新增 `_get_modelinfo_module_hash` 静态方法: 在 `vllm/model_executor/models/registry.py` 的 `_LazyRegisteredModel` 类中新增, 接受 `model_path` 参数, 若文件名是 `__init__.py`, 则对包目录下所有 `.py` 文件 (`rglob("*.py")`) 按字典序读取内容并计算累积哈希; 否则仅对单文件哈希。
2. 替换 `inspect_model_cls` 中的哈希逻辑: 将原来直接对单文件 `safe_hash` 的调用改为调用 `self._get_modelinfo_module_hash(model_path)`, 复用新逻辑。
3. 新增回归测试: 在 `tests/models/test_registry.py` 中新增 `test_lazy_modelinfo_package_hash_includes_submodules`, 创建一个临时包目录, 修改子模块文件后断言两次哈希不同, 确保缓存正确失效。
4. 导入调整与测试优化: 测试文件新增 `_LazyRegisteredModel` 导入; 最后一次提交修复了 `import` 顺序。

关键文件:

- `vllm/model_executor/models/registry.py` (模块 模型注册; 类别 `source`; 类型 `data-contract`; 符号 `_get_modelinfo_module_hash`): 核心变更文件, 新增 `_get_modelinfo_module_hash` 静态方法并替换 `inspect_model_cls` 中的哈希逻辑, 是影响缓存正确性的关键改动。
- `tests/models/test_registry.py` (模块 测试; 类别 `test`; 类型 `test-coverage`; 符号 `test_lazy_modelinfo_package_hash_includes_submodules`): 新增回归测试 `test_lazy_modelinfo_package_hash_includes_submodules`, 通过临时包目录验证子模块变更会导致哈希变化, 是验证正确性的关键。

关键符号: `_get_modelinfo_module_hash`

关键源码片段

`vllm/model_executor/models/registry.py`

核心变更文件, 新增 `_get_modelinfo_module_hash` 静态方法并替换 `inspect_model_cls` 中的哈希逻辑, 是影响缓存正确性的关键改动。

```
@staticmethod
def _get_modelinfo_module_hash(model_path: Path) -> str:
    if model_path.name == "__init__.py":
        # Package entry points often re-export classes implemented in
        # submodules, so include the package contents in the cache key.
        module_paths = sorted(model_path.parent.rglob("*.py"))
        root_path = model_path.parent
    else:
        # 单文件模型保持原有单文件哈希路径
        module_paths = [model_path]
        root_path = model_path.parent

    hasher = safe_hash(b"", usedforsecurity=False)
    for path in module_paths:
        # 使用相对路径作为标识, 避免绝对路径泄露
        hasher.update(path.relative_to(root_path).as_posix().encode("utf-8"))
        hasher.update(b"\0")
        # 读取文件内容参与哈希
        hasher.update(path.read_bytes())
        hasher.update(b"\0")
    return hasher.hexdigest()
```

`tests/models/test_registry.py`

新增回归测试 `test_lazy_modelinfo_package_hash_includes_submodules`, 通过临时包目录验证子模块变更会导致哈希变化, 是验证正确性的关键。

```
def test_lazy_modelinfo_package_hash_includes_submodules(tmp_path):
    # 模拟一个包式模型注册: __init__.py 从 .model 子模块导入 Model
    package_dir = tmp_path / "model_package"
    package_dir.mkdir()
    init_file = package_dir / "__init__.py"
    init_file.write_text("from .model import Model\n", encoding="utf-8")
    model_file = package_dir / "model.py"
    model_file.write_text("class Model: pass\n", encoding="utf-8")

    # 计算首次哈希
    first_hash = _LazyRegisteredModel._get_modelinfo_module_hash(init_file)

    # 修改子模块文件, 预期哈希变化
    model_file.write_text(
        "class Model:\n    supports_pp = True\n", encoding="utf-8"
```

```
)  
second_hash = _LazyRegisteredModel._get_modelinfo_module_hash(init_file)  
  
# 断言：子模块变更应导致缓存失效  
assert first_hash != second_hash
```

评论区精华

PR 讨论较少，Hmellor 批准后仅提及 CI 失败的 Hugging Face 429 问题（不相关）。无技术争议。

- 暂无高价值评论线程

风险与影响

- 风险：低风险。变更集中在缓存键计算逻辑，不影响功能正确性。包遍历 `rglob("*.py")` 在包目录较大时可能引入轻微性能开销，但模型信息缓存本身仅在首次加载或文件变更时计算，频率极低。测试覆盖了包场景和单文件场景的退化路径。
- 影响：影响范围小，仅涉及 `_LazyRegisteredModel` 的缓存哈希计算。对用户无直接感知，但能避免因缓存误命中导致模型 `capability` 信息过时而引发的调试困扰。团队在维护硬件特定模型（如 `vllm.models.minimax_m3`）时会从中受益。
- 风险标记：低风险

关联脉络

- PR #45810 [MiniMax-M3] PP support: PR 中提及该模型注册是包式的，且发现此缓存问题的场景。