

PR #52647 完整报告

vllm-project/vllm

[ROCm][CI] Expand AITER W4A4 MoE Coverage

合并时间: 2026-08-18 04:46

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/52647>

执行摘要

- 一句话: 扩展 AITER W4A4 MoE 测试, 补回退用例与激活量化参考
- 推荐动作: 值得快速浏览。虽然没有生产代码, 但两层设计有借鉴价值: 一是用“环境变量 + 模块级标志双控制”的 fixture 在同一台真机上同时验证开启与回退两条路径; 二是 oracle 参考路径如何精确模拟激活量化误差。对负责 ROCm 内核后端选择的工程师有直接参考价值。

功能与动机

PR body 明确两个目标: 其一, 在 GFX950 上用显式 AITER 开 / 关 fixture 测试 w4a4 后端选择 (“Test gfx950 w4a4 backend selection with explicit AITER on/off fixtures, including a no-ITER emulation fallback test”), 覆盖无 AITER 时的 EMULATION 回退; 其二, 扩展现有 mxfp4 MoE oracle 测试以覆盖 `AITER_MXFP4_MXFP4`, 并在参考路径中加入 mxfp4 激活量化 (“with mxfp4 activation quantization in the reference path”)。背景是 AITER 新增了激活也走 MXFP4 的 W4A4 MoE 后端, 而既有测试只覆盖 BF16/FP8 激活变体, 且只能被动依赖运行环境中 AITER 是否启用, 无法验证“禁用 AITER 时正确回退”这一关键路径。

实现拆解

1. GFX950 后端选择测试的可控化 (`tests/quantization/test_gfx950_moe.py`)
 1. 模块级探测从 `rocm_aiter_ops.is_fused_moe_enabled()` 改为 `is_aiter_found_and_supported()` (从 `vllm._aiter_ops` 导入), 把“AITER 库可用”与“进程内已启用”两个概念解耦, 为后续通过 fixture 动态切换 AITER 开关铺路。
 2. 新增 `set_rocm_aiter(monkeypatch, enabled)`: 同时写 `VLLM_ROCM_USE_AITER` 与 `VLLM_ROCM_USE_AITER_MOE` 环境变量, 并 monkeypatch `rocm_aiter_ops._AITER_ENABLED` 与 `_FMOE_ENABLED` 两个模块级标志, 保证 `select_mxfp4_moe_backend` 运行时读到测试期望的状态。
 3. `test_w4a4_dispatches_to_aiter` 改为依赖 `enable_rocm_aiter` fixture, 跳过条件从“AITER 已启用”放宽为“AITER 受支持”; 新增 `test_w4a4_falls_back_without_aiter`, 在 `disable_rocm_aiter` 下断言 W4A4 回退到 `Mxfp4MoeBackend.EMULATION`, 从而在真机上同时覆盖“走 AITER 内核”与“回退实现”两条分支。

2. oracle 参考路径加入 mxfp4 激活量化 (tests/kernels/moe/test_ocp_mx_moe.py)

1. 新增 mxfp4_quant_dequant: 先用 dynamic_mxfp4_quant 按 block 做动态量化, 再用 upcast_from_mxfp 反量化回 bf16/fp32, 精确模拟内核中激活量化的精度损失。
2. reference_moe 支持 act_type == "mxfp4": 在 MLP #1 输入前与激活后 (MLP #2 前) 各做一次量化 - 反量化; 原先只有 mxfp8 分支在激活后做量化。
3. ROCM_BACKEND_CONFIGS 新增 AITER_MXFP4_MXFP4 (activation=SILU、act_type=mxfp4、rtol=1.0、percent=0.8), 并把参考路径的 act_type 改为从配置读取 (默认 bf16), 使精度断言随后端变体变化。

3. 测试与 CI 配套

无 schema、配置或部署改动; CI 由维护者 /ci run 触发 Buildkite CI #84252; PR body 声明两个测试文件在 MI355 本地通过。

关键文件:

- tests/quantization/test_gfx950_moe.py (模块 后端选择; 类别 test; 类型 test-coverage ; 符号 set_rocm_aiter, enable_rocm_aiter, disable_rocm_aiter, test_w4a4_dispatches_to_aiter) : 本次 PR 的核心: 将 AITER 探测与启用解耦, 引入 enable/disable fixture 显式控制 AITER 状态, 并新增无 AITER 时回退 EMULATION 的用例, 覆盖后端选择的两条关键分支。
- tests/kernels/moe/test_ocp_mx_moe.py (模块 精度测试; 类别 test; 类型 test-coverage ; 符号 mxfp4_quant_dequant, reference_moe, test_rocm_mxfp4_moe_oracle) : 扩展 oracle 参考实现支持 mxfp4 激活量化, 并新增 AITER_MXFP4_MXFP4 后端配置, 使 W4A4 内核精度可被真实数值校验。

关键符号: set_rocm_aiter, enable_rocm_aiter, disable_rocm_aiter, test_w4a4_dispatches_to_aiter, test_w4a4_falls_back_without_aiter, mxfp4_quant_dequant, reference_moe, test_rocm_mxfp4_moe_oracle

关键源码片段

tests/quantization/test_gfx950_moe.py

本次 PR 的核心: 将 AITER 探测与启用解耦, 引入 enable/disable fixture 显式控制 AITER 状态, 并新增无 AITER 时回退 EMULATION 的用例, 覆盖后端选择的两条关键分支。

```
# 通过 fixture 显式控制 AITER 开关, 让同一台 GFX950 上能同时覆盖
# “走 AITER 内核”与“回退 EMULATION”两条分支。
def set_rocm_aiter(monkeypatch: pytest.MonkeyPatch, enabled: bool) -> None:
    value = "1" if enabled else "0"
    # 同时改环境变量与模块级标志位:
    # 环境变量是 select_mxfp4_moe_backend 的运行时判定依据,
    # 模块级 _AITER_ENABLED / _FMOE_ENABLED 用于覆盖进程内缓存状态。
    monkeypatch.setenv("VLLM_ROCM_USE_AITER", value)
    monkeypatch.setenv("VLLM_ROCM_USE_AITER_MOE", value)
    monkeypatch.setattr(rocm_aiter_ops, "_AITER_ENABLED", enabled)
```

```
monkeypatch.setattr(rocm_aiter_ops, "_FMOE_ENABLED", enabled)
```

```
@pytest.fixture
```

```
def enable_rocm_aiter(monkeypatch: pytest.MonkeyPatch):  
    set_rocm_aiter(monkeypatch, True)
```

```
@pytest.fixture
```

```
def disable_rocm_aiter(monkeypatch: pytest.MonkeyPatch):  
    set_rocm_aiter(monkeypatch, False)
```

```
@pytest.mark.skipif(not ROCM_GFX950, reason="Requires GFX950 (mi355x)")
```

```
# 只要求 GFX950、不要求 AITER 存在——正好验证“无 AITER 环境”的兜底路径。
```

```
def test_w4a4_falls_back_without_aiter(  
    mxfp4_oracle_config,  
    disable_rocm_aiter,  
):  
    config = _make_w4a4_moe_config()  
    backend, experts_cls = select_mxfp4_moe_backend(  
        config, activation_key=kMxfp4Dynamic  
    )  
    # 关闭 AITER 后，W4A4 必须回退到 EMULATION 实现而不是报错。  
    assert backend == Mxfp4MoeBackend.EMULATION  
    assert experts_cls is not None
```

tests/kernels/moe/test_ocp_mx_moe.py

扩展 oracle 参考实现支持 mxfp4 激活量化，并新增 AITER_MXFP4_MXFP4 后端配置，使 W4A4 内核精度可被真实数值校验。

```
def mxfp4_quant_dequant(x: torch.Tensor) -> torch.Tensor:
```

```
    """参考路径里的 mxfp4 激活量化。
```

```
    先用 dynamic_mxfp4_quant 按 block 做动态量化，再用 upcast_from_mxfp  
    反量化回 bf16，模拟 AITER_MXFP4_MXFP4 内核中“激活也走 MXFP4”  
    带来的精度损失，让参考实现与真实内核对齐。
```

```
    """
```

```
    shape = x.shape  
    # flatten(0, -2) 保证最后一维连续，便于 scale block 对齐。  
    quantized, scale = dynamic_mxfp4_quant(x.to(torch.bfloat16).flatten(0, -2))  
    return (  
        upcast_from_mxfp(quantized.view(torch.uint8), scale, torch.bfloat16, axis=-1)  
        .reshape(shape)  
        .float()  
    )
```

```
# reference_moe 中新增的 mxfp4 分支（节选）：
```

```

# MLP #1 之前，输入激活先做一次量化 - 反量化（原先只有权重是 MXFP4）。
t = hidden_states.clone()
if act_type == "mxfp4":
    t = mxfp4_quant_dequant(t)

# 激活之后、MLP #2 之前再补一次；原先只有 mxfp8 分支做激活后量化。
if act_type == "mxfp8":
    t_quantized, t_scale = mxfp8_quantize(
        t.to(torch.bfloat16), is_sf_swizzled_layout=False
    )
    t = mxfp8_dequantize(t_quantized, t_scale)
elif act_type == "mxfp4":
    t = mxfp4_quant_dequant(t)

```

评论区精华

review 讨论非常精简：claude[bot] 提示该 PR 来自 fork，自动化 review 被禁用，维护者可用 [@claude review](#) 手动触发（最终未执行）；维护者 AndreasKaratzas 直接 APPROVED 并仅给出 "LGTM"，没有任何质疑性 comment。需要留意的是，评论中未讨论两处潜在问题：一是 [_AITER_ENABLED](#) / [_FMOE_ENABLED](#) 这类私有标志 monkeypatch 的脆弱性；二是 [AITER_MXFP4_MXFP4](#) 的 `rtol=1.0` 相对宽松，是否足够证明内核正确性。

- fork PR 自动化 review 未启用 (other): 未触发额外 review，最终由维护者 AndreasKaratzas 人工 APPROVED。
- CI 触发与本地验证 (question): CI 已触发，review 无进一步疑问后合并。

风险与影响

- 风险：生产风险为零，全部改动位于测试文件。主要风险点：1) `set_rocm_aiter` 依赖 `rocm_aiter_ops._AITER_ENABLED` / `_FMOE_ENABLED` 私有属性，若 AITER 封装改名或改为惰性读取环境变量，测试可能静默跳过或误判，属于对内部实现的耦合；2) `AITER_MXFP4_MXFP4` 的 `rtol=1.0` 允许 100% 相对误差且 `percent=0.8`，精度断言偏弱，存在“通过但精度损失明显”的假阴性风险；3) 两条新用例的 `skip` 条件依赖 GFX950 与 AITER 支持，普通 CI 机器不会执行，实际守护效果取决于 ROCm 硬件 CI 是否常驻 MI355；4) `is_aiter_found_and_supported()` 是新引入的探测 API，若其语义变化会影响测试有效性。
- 影响：影响面局限于 ROCm/GFX950 专属测试矩阵：为 `AITER_MXFP4_MXFP4` 后端选择与精度提供回归基线，对运行用户与服务端行为零影响。对团队而言，补齐了 W4A4 激活量化路径的验证缺口，后续在 MI355 上的 AITER 内核改动会立即被这两条新用例守护；同时它也是近两周 ROCm CI 稳定性加固工作的一部分。
- 风险标记：仅测试改动，依赖私有标志位，精度阈值偏宽，硬件专属测试

关联脉络

- PR #52566 [ROCm][CI] Restore Torch defaults and type DSV4 scratch buffers: 同属 ROCm CI 测试稳定性修复方向，本 PR 合入后共用 MI355 硬件 CI 资源，体现 ROCm 测

试矩阵的持续加固。

- PR #52502 [Hardware][NVIDIA] Add GB10 fused-MoE fp8 tuning configs (E=256, E=512): 同属 MoE 量化后端配置与精度验证脉络, 说明 fused-MoE 后端矩阵正在多平台扩展, 本 PR 的 AITER_MXFP4_MXFP4 用例是 ROCm 侧的补位。
- PR #51114 [Perf][MoE] Optimize deepep_v2 receiver CPU Overhead: 同属 MoE 内核实现 / 验证链路, 体现 fused MoE 多后端并存下测试配套的演进方向。