

PR #46769 完整报告

vllm-project/vllm

[CPU] Fix macOS/Apple Silicon hang by enabling OpenMP in the build

合并时间: 2026-06-27 02:32

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46769>

执行摘要

此 PR 修复了 macOS CPU 上因构建未传递 `-fopenmp` 标志导致的 attention split-KV 死锁问题。核心方案是: 通过 `cmake` 添加 `-Xpreprocessor -fopenmp` 启用 OpenMP, 并将所有 CPU 内核的线程数获取封装为 `cpu_utils::get_max_threads()`, 在无 OpenMP 时安全降级为串行。同时改进了 CI 烟雾测试以覆盖该路径, 并调整了 CI 矩阵。变更涉及 10 个文件, 已合入 main。

功能与动机

macOS CPU 构建在 #16086 后未传递 `-fopenmp`, 导致 `#pragma omp parallel` 被编译器忽略, 但 `omp_get_max_threads()` 仍报告全部核心。attention 的 split-KV 路径在 barrier 上等待从未启动的线程团队, 从而死锁。短 prompt 可侥幸逃过, 但长 prompt 必然触发。此 PR 从根本修复, 替代了之前的 workaround #45649 (强制 `OMP_NUM_THREADS=1`, 但导致 attention 单线程化)。

实现拆解

1. 添加编译标志: 在 `cmake/cpu_extension.cmake` 中为 Apple Clang 添加 `-Xpreprocessor -fopenmp`, 无需额外链接, `_C` 通过 `dynamic_lookup` 从 torch 解析 libomp。
2. 封装线程数获取: 在 `csrc/cpu/cpu_types.hpp` 的 `cpu_utils` 命名空间中新增 `get_max_threads()`: 有 OpenMP 时返回 `omp_get_max_threads()`, 否则返回 1 并警告。
3. 替换内核调用: 在 6 个源文件 (`cpu_attn_impl.hpp`、`cpu_fused_moe.cpp`、`cpu_wna16.cpp`、`dnnl_kernels.cpp`、`mla_decode.cpp`) 中共 7 处将 `omp_get_max_threads()` 改为 `cpu_utils::get_max_threads()`。
4. 改进 CI 烟雾测试: `.github/workflows/macos-smoke-test.yml` 发送约 260 token 的 prompt 以触发 split-KV 路径; CI 矩阵固定为门控 macos-15 (Clang 16) 和非阻塞 macos-26 (Clang 17); `.github/actionlint.yml` 允许预览标签 macos-26。
5. 更新文档: `docs/getting_started/installation/cpu.apple.inc.md` 补充 OpenMP 依赖说明。

`csrc/cpu/cpu_types.hpp`

新增 `cpu_utils::get_max_threads()` 封装函数, 这是本次修复的核心抽象, 确保非 OpenMP 构建安全降级。

```
#ifndef CPU_TYPES_HPP
#define CPU_TYPES_HPP
```

```

#if defined(__x86_64__)
    #include "cpu_types_x86.hpp"
#elif defined(__aarch64__)
    #include "cpu_types_arm.hpp"
// ... 其他架构分支省略 ...
#else
    #include "cpu_types_scalar.hpp"
#endif

#ifdef _OPENMP
    #include <omp.h>
#endif

#include <c10/util/Exception.h>

namespace cpu_utils {
// 当没有 OpenMP 时, `#pragma omp parallel` 区域会编译为串行循环,
// 如果内核基于线程数做屏障 (barrier), 就会导致死锁。
// 因此返回 1, 并给出一次性警告。
inline int get_max_threads() {
#ifdef _OPENMP
    return omp_get_max_threads();
#else
    TORCH_WARN_ONCE(
        "vLLM CPU was built without OpenMP; running single-threaded.");
    return 1;
#endif
}
} // namespace cpu_utils

#endif

```

评论区精华

WindChimeRan: "Solution LGTM ... One risk: this PR has only been tested on macOS 26 / clang 21, and no macOS CI runs on this PR. It may break on macos-15 clang 17, and if so, it will break as a loading error, worse than today's hang, and `cpu_utils::get_max_threads()` cannot prevent loading error."

mgoin: "Ran the smoke test on this branch before merge — both legs green, including macos-15 / Apple Clang 16. So the load-error worst case doesn't show up."

风险与影响

- 兼容性风险: `-Xpreprocessor -fopenmp` 在更早 Apple Clang 上可能失效, 但 CI 覆盖了 macos-15 (Clang 16) 并通过。
- 降级风险: 非 OpenMP 构建串行运行但不会死锁。

- 加载风险: libomp 加载失败可能导致 `_C` 导入错误, 但 torch 始终提供 libomp, 且加载路径与已有 `omp_get_max_threads` 一致。
- 正面影响: macOS CPU 用户可处理长 prompt 且 attention 多线程加速; 移除了临时 workaround, 降低维护成本。

关联脉络

此 PR 直接替代了 #45649 (强制单线程的 workaround), 并修复了 #16086 引入的回归 (添加 `omp.h` 但未传递 `-fopenmp`)。相关 issue #15941 讨论了 macOS 上的 OpenMP 兼容性问题。这些改进是 vLLM CPU 后端持续完善的一部分, 确保在 Apple Silicon 上的可用性和性能。