

PR #48333 完整报告

vllm-project/vllm

fix(entrypoints): stop resolve_items leaking in-flight media fetch tasks on partial failure

合并时间: 2026-07-11 23:42

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/48333>

执行摘要

- 一句话: 修复媒体获取任务泄漏问题
- 推荐动作: 建议阅读。这是一个典型的 `asyncio` 并发控制模式改进, 对理解异步任务泄露和 `asyncio.gather` 的正确使用有学习价值。

功能与动机

当单个消息包含多个图片 / 音频时, 一个媒体项获取失败 (如 URL 错误、超时、SSRF 拒绝、解码错误) 会导致同批次其他仍在进行中的获取任务被遗弃, 泄漏网络 `socket` 和 `global_thread_pool` 工作, 且无法取消。PR body 提供了可复现的代码示例。

实现拆解

1. 修改核心获取逻辑(vllm/entrypoints/chat_utils.py): 将 `AsyncMultiModalItemTracker.resolve_items` 中每模态的 `asyncio.gather` 调用添加 `return_exceptions=True` 参数, 使所有任务完成后才返回结果。
2. 异常收集与重新抛出: 在 `gather` 返回后遍历结果列表, 若捕获到 `BaseException` 子类实例, 则抛出第一个异常, 确保异常传播正确。
3. 添加回归测试(tests/entrypoints/unit_tests/test_chat_utils.py): 新增 `test_resolve_items_does_not_leak_tasks_on_partial_failure` 测试, 构造一个失败和两个慢成功的获取任务, 通过 `asyncio.all_tasks()` 对比验证无任务泄漏。

关键文件:

- `vllm/entrypoints/chat_utils.py` (模块 请求处理; 类别 `source`; 类型 `core-logic`; 符号 `resolve_items`): 核心修复文件, 修改 `AsyncMultiModalItemTracker.resolve_items` 方法, 将 `asyncio.gather` 改为 `return_exceptions=True` 并后处理异常。
- `tests/entrypoints/unit_tests/test_chat_utils.py` (模块 单元测试; 类别 `test`; 类型 `test-coverage`; 符号 `test_resolve_items_does_not_leak_tasks_on_partial_failure, _fetch`): 新增回归测试, 验证 `fix` 后无任务泄漏。

关键符号: `AsyncMultiModalItemTracker.resolve_items`

关键源码片段

`vllm/entrypoints/chat_utils.py`

核心修复文件，修改 AsyncMultiModalItemTracker.resolve_items 方法，将 asyncio.gather 改为 return_exceptions=True 并后处理异常。

```
# vllm/entrypoints/chat_utils.py (AsyncMultiModalItemTracker.resolve_items)
```

```
async def resolve_items(self) -> tuple[MultiModalDataDict | None, MultiModalUUIDDict | None]:
    if not self._items_by_modality:
        return None, None

    resolved_items_by_modality: dict[str, list[Any]] = {}
    for modality, items in self._items_by_modality.items():
        # return_exceptions=True 确保所有 tasks 都完成（或失败）后才返回，
        # 而不是在第一个异常时立即传播，导致仍在运行的 tasks 泄漏。
        results = await asyncio.gather(
            *(item() for item in items), return_exceptions=True
        )
        for result in results:
            if isinstance(result, BaseException):
                # 找到第一个异常并抛出，但此时所有 tasks 已完成。
                raise result
        resolved_items_by_modality[modality] = results

    mm_processor = (
        self.mm_processor if self._model_config.is_multimodal_model else None
    )
    return _resolve_items(
        resolved_items_by_modality,
        mm_processor,
        self._modality_order,
    )
```

tests/entrypoints/unit_tests/test_chat_utils.py

新增回归测试，验证 fix 后无任务泄漏。

```
# tests/entrypoints/unit_tests/test_chat_utils.py (新增测试函数)
```

```
@pytest.mark.asyncio
async def test_resolve_items_does_not_leak_tasks_on_partial_failure():
    """Regression test: one failing fetch must not leave sibling tasks running."""

    async def _fetch(should_fail: bool, delay: float):
        # 模拟失败或成功延迟的 fetch
        if should_fail:
            await asyncio.sleep(0.01)
            raise ValueError("simulated fetch failure")
        await asyncio.sleep(delay)
        return ("decoded", None)

    # 构造 tracker 包含 1 个失败和 2 个慢成功的 fetch
```

```

tracker = AsyncMultiModalItemTracker(MagicMock())
tracker._items_by_modality["image"] = [
    lambda: _fetch(True, 0),
    lambda: _fetch(False, 0.2),
    lambda: _fetch(False, 0.2),
]

tasks_before = asyncio.all_tasks()
with pytest.raises(ValueError, match="simulated fetch failure"):
    await tracker.resolve_items()

# 确保没有新增遗留任务
leaked_tasks = asyncio.all_tasks() - tasks_before
assert not leaked_tasks, (
    f"resolve_items left {len(leaked_tasks)} task(s) running after "
    f"raising: {leaked_tasks}"
)

```

评论区精华

无 review 评论。仅 CI pre-commit 检查发现一个格式问题 (trailing blank line)，由作者 ErenAta16 在第二个 commit 中修复。DarkLight1337 直接批准了 PR。

- 暂无高价值评论线程

风险与影响

- 风险：主要的权衡是：之前的实现会在第一个失败时立即报错（快速失败），而修复后需要等待同模态最慢的任务完成后才报错，可能增加 p99 延迟。但这是合理的取舍，因为避免了资源泄漏。
- 影响：影响所有使用多模态输入的请求路径。修复了在部分媒体获取失败时资源泄漏的 bug，提高系统稳定性和资源利用率。
- 风险标记：延迟权衡：等待慢任务增加 p99

关联脉络

- PR #43117 fix(processor): route MiMo-V2-Omni media fetch through MediaConnector: 同样涉及多模态媒体获取路径，修复了相关安全问题。