

PR #40148 完整报告

vllm-project/vllm

fix(openai): tolerate empty content in forced tool choice

合并时间: 2026-05-06 22:16

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/40148>

执行摘要

- 一句话: 修复 forced tool_choice 在 content=None 时的断言崩溃
- 推荐动作: 值得精读。该 PR 展示了如何正确修复推理解析与工具调用交互的边界情况, 并包含 review 中设计决策的来回迭代, 对理解工具调用流程有参考价值。

功能与动机

Issue #40147 报告: 推理解析器返回 content=None 时, forced tool_choice 触发 AssertionError, 导致服务器错误而非有效的空函数调用。需要使服务器能够优雅处理 content 为 None 的情况, 符合 OpenAI 行为。

实现拆解

1. 修改 OpenAIServing._parse_tool_calls_from_content (vllm/entrypoints/openai/engine/serving.py): 在 Responses API 的 ToolChoiceFunction 分支和 ChatCompletion 的 ChatCompletionNamedToolChoiceParam 分支中, 将 assert content is not None 替换为 if content is None: return [], None, 确保 content 为空时不构造 FunctionCall。
2. 修改 DelegatingParser._parse_tool_calls (vllm/parser/abstract_parser.py): 同样将 forced function call 分支的断言改为条件返回空列表。
3. 调整 chat_completion/serving.py 中 tool_calls 的断言: 将 assert tool_calls is not None and len(tool_calls) > 0 简化为 tool_calls = tool_calls or [], 避免 tool_calls 为 None 时崩溃。
4. 新增单元测试文件 tests/entrypoints/openai/test_tool_choice_content_none.py, 覆盖 ChatCompletion 和 Responses 路径中 named tool_choice 传递 content=None 的场景。
5. 扩展端到端测试 test_max_tokens_with_tool_choice_required (tests/entrypoints/openai/chat_completion/test_completion_with_function_calling.py), 通过参数化同时测试 'required' 和 named function 两种 tool_choice。

关键文件:

- vllm/entrypoints/openai/engine/serving.py (模块 服务层; 类别 source; 类型 core-logic; 符号 _parse_tool_calls_from_content): 核心修复文件, 在 _parse_tool_calls_from_content 中添加 content 为 None 的守卫条件。

- `vllm/parser/abstract_parser.py` (模块 解析器; 类别 `source`; 类型 `core-logic`; 符号 `_parse_tool_calls`) : 在 `DelegatingParser._parse_tool_calls` 中做相同修复。
- `tests/entrypoints/openai/test_tool_choice_content_none.py` (模块 测试; 类别 `test`; 类型 `test-coverage`; 符号 `_DummyDelegatingParser`, `test_parse_tool_calls_from_content_allows_named_tool_choice_with_none_content`, `test_responses_parser_allows_named_tool_choice_with_none_content`) : 新增回归测试, 验证 `content=None` 时返回空工具调用。
- `tests/entrypoints/openai/chat_completion/test_completion_with_function_calling.py` (模块 函数调用测试; 类别 `test`; 类型 `test-coverage`; 符号 `test_max_tokens_with_tool_choice_required`) : 扩展端到端测试, 覆盖 `named tool_choice` 场景。
- `vllm/entrypoints/openai/chat_completion/serving.py` (模块 服务层; 类别 `source`; 类型 `core-logic`; 符号 `chat_completion_full_generator`) : 修复流式响应中 `tool_calls` 断言过于严格。

关键符号: `_parse_tool_calls_from_content`, `_parse_tool_calls`, `chat_completion_full_generator`

关键源码片段

`vllm/entrypoints/openai/engine/serving.py`

核心修复文件, 在 `_parse_tool_calls_from_content` 中添加 `content` 为 `None` 的守卫条件。

```
# 在 _parse_tool_calls_from_content 方法中处理强制工具调用的两个分支:
# 1. ToolChoiceFunction (Responses API)
# 2. ChatCompletionNamedToolChoiceParam (Chat API)
# 此前使用 assert content is not None 会在此处抛出异常,
# 现在改为守卫条件, 当 content 为 None 时直接返回空列表。

# 分支 1: Responses API forced function call
if (
    not use_mistral_tool_parser
    and request.tool_choice
    and isinstance(request.tool_choice, ToolChoiceFunction)
):
    # 当推理解析器 (如 DeepSeekV3ReasoningParser) 返回 content=None 时,
    # 返回空列表, 避免 assert 崩溃
    if content is None:
        return [], None
    function_calls.append(
        FunctionCall(name=request.tool_choice.name, arguments=content)
    )
    content = None # 标记 content 已用于工具调用

# 分支 2: ChatCompletion named tool choice
elif (
    not use_mistral_tool_parser
```

```

and request.tool_choice
and isinstance(request.tool_choice, ChatCompletionNamedToolChoiceParam)
and (tool_parser_cls is None or tool_parser_cls.supports_required_and_named)
):
    # 同样，content 为 None 时返回空列表
    if content is None:
        return [], None
    function_calls.append(
        FunctionCall(name=request.tool_choice.function.name, arguments=content)
    )
    content = None

```

tests/entrypoints/openai/test_tool_choice_content_none.py

新增回归测试，验证 content=None 时返回空工具调用。

```

class _DummyDelegatingParser(DelegatingParser):
    """模拟一个始终返回 None 的推理解析器"""
    def extract_reasoning(self, model_output: str, request):
        # 返回 (None, model_output) 触发 content=None 场景
        return None, model_output
    # 其他方法省略 ...

def test_parse_tool_calls_from_content_allows_named_tool_choice_with_none_content():
    """验证 ChatCompletion named tool_choice 在 content=None 时返回空列表"""
    request = ChatCompletionRequest.model_validate({
        "model": "test-model",
        "messages": [{"role": "user", "content": "test"}],
        "tools": [{
            "type": "function",
            "function": {"name": "get_weather", "parameters": {}},
        }],
        "tool_choice": {"type": "function", "function": {"name": "get_weather"}},
    })
    tool_calls, content = OpenAIServing._parse_tool_calls_from_content(
        request=request, tokenizer=None, enable_auto_tools=True,
        tool_parser_cls=None, content=None,
    )
    assert content is None
    assert tool_calls is not None
    assert tool_calls == [] # 现在是空列表，而非崩溃

```

评论区精华

Reviewer chaunceyjiang 最初建议在 DeepSeek 解析器中修复 ("Perhaps it would be better to modify the corresponding parser")，但作者 QwertyJack 重写后，reviewer 纠正了自己的看法 ("I realized I was wrong earlier")，并指出更正确的修复是当 content 为 None 时返回空工具调用列表 ([])，而不是拼接空的参数字符串。最终方案采纳了这一建议，并移除了之前尝试的 content = content or '' 逻辑。讨论还涉及 arguments 应使用 "{}" 还是 "

", 但最终决定直接返回空列表, 符合 OpenAI 行为。

- 修复位置: 改 parser 还是改入口? (design): 最终在 shared forced-tool handling 路径中返回空列表, 不修改 DeepSeek parser。
- arguments 格式: 应使用 "{}" 还是 ""? (design): 最终决定不合成函数调用, 而是返回空列表 [], 避免 arguments 格式争议。
- 是否需要合成空的 FunctionCall? (design): 采纳空列表, 与 OpenAI 行为一致。

风险与影响

- 风险: 风险极低: 改动仅限于 forced tool_choice 路径中 content 为 None 的边界情况, 替换断言为条件返回, 不会影响其他 tool_choice 模式 (auto, required, none)。新增单元测试覆盖 ChatCompletion 和 Responses 两种入口, 扩展的端到端测试覆盖了 max_tokens 触发 content 为 None 的场景。唯一潜在风险是如果调用方依赖原先的断言行为 (即期望服务器报错), 但这是从内部错误恢复为正常响应, 更符合预期。
- 影响: 对用户: 修复了 DeepSeek V3 等带推理的模型在使用 forced tool_choice 时可能返回 500 服务器错误的问题, 现在会正确返回空工具调用。对系统: 无性能开销, 分支判断仅在 content 为 None 时执行。对团队: 代码更健壮, 减少了类似异常的排查成本。
- 风险标记: 边界条件处理, 测试覆盖新增

关联脉络

- PR #40147 [Bug]: forced tool_choice asserts when reasoning extraction returns content=None: 直接关联的 issue, 描述问题根因和复现步骤。