

PR #44361 完整报告

vllm-project/vllm

[Bugfix] Responses API assistant EasyInputMessageParam input

合并时间: 2026-06-23 20:54

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/44361>

执行摘要

- 一句话: 修复 Responses API 助手消息字符串内容解析错误
- 推荐动作: 建议阅读本 PR, 特别是 `protocol.py` 中 `input_item_parsing` 的改动模式。它展示了在 Pydantic 强制转换前增加类型守卫以绕过验证错误的典型手法。同时关注讨论中关于缺少模型定义的思考, 提示团队后续需重构以消除对字典的依赖。

功能与动机

用户在使用 Responses API 时, 传入形如 `{"role": "assistant", "type": "message", "content": "some string"}` 的输入会触发 `BadRequestError`, 错误信息包含 `2 validation errors for ValidatorIterator: 0.ResponseOutputTextParam, 0.ResponseOutputRefusalParam`。根本原因是 `assistant` 的字符串内容被不当强制为 `ResponseOutputMessage`, 导致 Pydantic 尝试将字符串中的每个字符解析为输出内容项。

实现拆解

1. 协议层防护 (`vllm/entrypoints/openai/responses/protocol.py`): 在 `ResponsesRequest.input_item_parsing` 方法中, 针对 `type: message, role: assistant` 的输入, 增加对 `content` 类型的检查。如果 `content` 不是列表 (即字符串), 则直接保留原始字典, 不再尝试创建 `ResponseOutputMessage` 对象, 避免后续 Pydantic 校验错误。
2. 工具调用构造扩展 (`vllm/entrypoints/openai/responses/utils.py`): 在 `_construct_message_from_response_item` 函数中新增分支, 处理字典类型的 `assistant` 消息。提取 `content` 字段, 若为字符串直接使用, 若为列表则取第一个元素的 `text` 字段, 然后与之前的 `assistant` 消息合并或生成新消息, 确保多轮对话历史正确。
3. 测试用例补充 (`tests/entrypoints/openai/responses/test_function_call_parsing.py`): 新增 `test_assistant_string_content_stays_easyinput` 验证字符串内容的 `assistant` 消息不会被强制转换; 新增 `test_assistant_output_style_content_coerced` 验证列表内容的 `assistant` 消息仍然能够正确转换为 `ResponseOutputMessage`。
4. `construct_chat_messages_with_tool_call` 测试增强 (`tests/entrypoints/openai/responses/test_responses_utils.py`): 新增参数化用例 `reasoning-easyinput-assistant`, 验证 `reasoning` 后跟随字典格式 `assistant` 消息的合并场景, 确保回归覆盖。

关键文件:

- `vllm/entrypoints/openai/responses/protocol.py` (模块 协议层; 类别 source; 类型 core-logic; 符号 `input_item_parsing`) : 核心修复: 在 `input_item_parsing` 中增加字符串内容检查, 避免不当强制转换
- `vllm/entrypoints/openai/responses/utils.py` (模块 工具层; 类别 source; 类型 core-logic; 符号 `_construct_message_from_response_item`) : 辅助修复: 扩展 `_construct_message_from_response_item` 处理字典格式 assistant 消息
- `tests/entrypoints/openai/responses/test_function_call_parsing.py` (模块 测试; 类别 test; 类型 test-coverage; 符号 `test_assistant_string_content_stays_easyinput`, `test_assistant_output_style_content_coerced`) : 新增两个单元测试, 验证字符串内容保留和列表内容强制转换的正确性
- `tests/entrypoints/openai/responses/test_responses_utils.py` (模块 测试; 类别 test; 类型 test-coverage) : 增强 `construct_chat_messages_with_tool_call` 的参数化测试, 添加 `reasoning-easyinput-assistant` 场景

关键符号: `input_item_parsing`, `_construct_message_from_response_item`,
`test_assistant_string_content_stays_easyinput`,
`test_assistant_output_style_content_coerced`

关键源码片段

`vllm/entrypoints/openai/responses/protocol.py`

核心修复: 在 `input_item_parsing` 中增加字符串内容检查, 避免不当强制转换

```
# vllm/entrypoints/openai/responses/protocol.py
# 在 ResponsesRequest.input_item_parsing 中, 处理 assistant 消息时
# 增加对 content 类型的判断: 字符串内容保留原始 dict, 避免 Pydantic 错误
```

```
elif item_type == "message" and item.get("role") == "assistant":
    content = item.get("content")
    # 如果 content 是字符串, 则是合法 EasyInputMessageParam
    # 不强制转换为 ResponseOutputMessage
    if not isinstance(content, list):
        processed_input.append(item)
        continue

    # 只有列表内容才尝试转为 ResponseOutputMessage
    original_item = item
    item = dict(item)
    if "id" not in item:
        item["id"] = f"msg_{random_uuid()}"
    if "status" not in item:
        item["status"] = "completed"
    # 补充 annotations 字段等逻辑 ...
    try:
        processed_input.append(ResponseOutputMessage(**item))
    except ValidationError:
        processed_input.append(original_item)
```

vllm/entrypoints/openai/responses/utils.py

辅助修复：扩展 `_construct_message_from_response_item` 处理字典格式 assistant 消息

```
# vllm/entrypoints/openai/responses/utils.py
# 在 _construct_message_from_response_item 中新增 elif 分支
# 处理未被协议层强制转换的 EasyInput 字典格式

elif isinstance(item, dict) and item.get("role") == "assistant":
    content = item.get("content")
    text: str | None = None
    if isinstance(content, str):
        text = content
    elif isinstance(content, list) and content:
        # 注意：这里只取第一个文本片段，多段内容会丢失
        text = content[0].get("text")
    if text is not None:
        if prev_assistant_msg:
            previous_content = prev_assistant_msg.get("content")
            if previous_content is None:
                prev_assistant_msg["content"] = text
            return None
        return {"role": "assistant", "content": text}
```

评论区精华

- bbrowning评论：在 `vllm/entrypoints/openai/responses/utils.py` 中直接处理字典类型的 assistant 消息，是否意味着缺少一个对应的 Pydantic 模型定义？感觉我们缺少了与 `ResponseOutputMessage` 对应的简单字符串版本模型。
- yzong-rh回应：`EasyInputMessageParam` 在 `openai` 包中被定义为 `TypedDict`，我们没有创建自己的 Pydantic 模型。可以通过自定义 Pydantic 模型并强制转换来解决，但当前改动镜像了已有行为。这个已知问题已在多个地方存在（如 `utils.py` 285-295 行），需要更全面的修复。
- 是否需要为字符串内容创建专门 Pydantic 模型 (design): 确认已知问题，本 PR 不解决，作为后续工作

风险与影响

- 风险：
 - 兼容性风险：改动仅限于输入解析路径，对于已存在的 `ResponseOutputMessage` 列表类型内容行为不变，向下兼容。
 - 功能覆盖不完整：讨论中已指出，`construct_chat_messages_with_tool_call` 中提取列表内容时只取 `content[0].get("text")`，对于多段 `input_text` 类型的列表会丢失部分内容。但此风险在修复前已存在，本 PR 未解决。
 - 测试覆盖：新增的两个单元测试和参数化用例覆盖了核心路径，但缺少对嵌套内容（如拒绝响应 `refusal` 字段）的测试，属于已知缺口。

- 影响：
 - 用户影响：所有使用 Responses API 并传入字符串内容 assistant 消息的用户将不再遇到验证错误，多轮对话正常工作。涉及非 harmony 和 harmony 两种模式。
 - 系统影响：改动集中在请求输入解析阶段，对推理性能无影响。
 - 团队影响：明确了 EasyInputMessageParam 与 ResponseOutputMessage 的边界，为后续创建专用 Pydantic 模型提供了基础。
 - 风险标记：多部分内容处理不完整，缺少专用 Pydantic 模型

关联脉络

- PR #46030 [Refactor] Responses API parser state into conversation context: 修改了相同的 responses/protocol.py 和 responses/utils.py 文件，属于同一功能线
- PR #44285 [Frontend] Split ServingRender into renderer and endpoint.: 涉及 Responses API 的渲染和消息构造，与当前改动有间接关联