

PR #50334 完整报告

vllm-project/vllm

[Bugfix][Responses] Add tests for Chat Completions Responses API Render Parity

合并时间: 2026-08-01 03:45

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/50334>

执行摘要

- 一句话: 新增双 API 渲染一致性测试并修复工具渲染差异
- 推荐动作: 值得精读, 重点是 `test_render_parity.py` 的捕获 - 对比测试设计: 它没有 mock 掉整个预处理链路, 只在 HF 渲染边界安装桩, 保留了两条 API 各自预处理逻辑的真实性, 这种 "边界打桩" 思路对其他跨 API 一致性测试有借鉴价值。也值得关注两个序列化器的白名单过滤与 `construct_tool_dicts` 的参数化设计。对后续要扩展 Responses API 能力的开发者, 这套测试应作为默认配套。

功能与动机

PR body 声明目标是为 Chat Completions 与 Responses 之间的渲染一致性添加测试, 覆盖多轮对话、tools (strict、defer_loading、extra 字段)、tool_choice、reasoning_effort/enable_thinking 以及 template kwargs。渲染入口的分叉会直接影响提示词模板输出, 进而影响工具调用正确性与响应质量。测试驱动下发现并修复两个不一致: 一是 Responses 的 FunctionTool 与 ChatCompletionToolsParam 渲染结果不一致 (该问题源于上游 PR#49824 的讨论), 二是 Responses 的 tool_choice='none' 未像 Chat Completions 那样尊重 --exclude-tools-when-tool-choice-none。行为变化随之产生: 工具中的 extra 自定义字段被忽略、tool_choice='none' 时默认把工具注入 prompt。

实现拆解

变更入口是新增的 `tests/entrypoints/openai/test_render_parity.py`: 它通过 `RenderCapture` 在 `render_chat_async` 这一 HF 渲染边界安装桩函数, 记录两套 API 各自预处理后产出的 messages 与 ChatParams, 再由 `_assert_parity` 以配对请求做逐字段断言。关键设计是没有 mock 掉 `OnlineRenderer.preprocess_chat` 链路, 只替换最末端的渲染函数, 因此 Chat Completions 与 Responses 各自的工具转换、消息构造逻辑都真实执行。

实现过程按以下步骤展开:

1. 建立跨 API 渲染捕获基础设施: 新增 `test_render_parity.py` (479 行), `MockModelConfig`/`MockHFConfig` 提供构造 `OnlineRenderer` 与 `OpenAIServingResponses` 所需的完整配置; `_capture_chat` 走 `online_renderer.render_chat`, `_capture_responses` 走 `serving._make_request`, 两者最终汇聚到同一个桩函数, 保证观测点在渲染边界完全一致。

2. 修复 FunctionTool 渲染不一致: vllm/entrypoints/openai/responses/utils.py 的 `convert_tool_responses_to_completions_format` 从返回裸 dict 改为构造 `ChatCompletionToolsParam`(`type="function"`, `function=FunctionDefinition.model_validate(...)`), 使 Responses 工具 schema 复用 Chat Completions 的字段校验与序列化; `construct_tool_dicts` 对应改为对转换结果调用 `.model_dump()`。配套在 vllm/entrypoints/openai/engine/protocol.py 的 `FunctionDefinition._serialize` 与 vllm/entrypoints/openai/chat_completion/protocol.py 的 `ChatCompletionToolsParam._serialize` 中加入按 `model_fields` 白名单过滤的逻辑, `strict`、`defer_loading` 为 `None` 时仍按原逻辑剔除——这是 `extra` 字段被统一忽略的实现来源。
3. 对齐 `tool_choice='none'` 语义: vllm/entrypoints/openai/responses/serving.py::`_make_request` 调用 `construct_tool_dicts` 时新增 `exclude_tools_when_tool_choice_none=self.online_renderer.exclude_tools_when_tool_choice_none` 透传, `construct_tool_dicts` 的判断条件由 `tool_choice == "none"` 改为 `tool_choice == "none" and exclude_tools_when_tool_choice_none`, 默认行为随之变为把工具写进 prompt。
4. 收敛非 function 工具并标记缺口: vllm/tool_parsers/utils.py::`iter_response_function_to_tool_dicts` 由无条件的 `else` 分支收紧为 `elif isinstance(tool, FunctionTool)`, `type="code_interpreter"` 等非 function 工具不再被注入; 该收紧暴露了 MCP 工具在 `ParsableContext` 路径从未被正确渲染的既有缺口, 最终对 `tests/entrypoints/openai/responses/test_parsable_context.py::test_mcp_tool_call` 加 `xfail` 并注明原因。
5. 测试配套收尾: `tests/entrypoints/openai/responses/test_responses_utils.py` 删除旧的裸 dict 断言用例 (`test_convert_tool_responses_to_completions_format`), 覆盖职责移交给新的 parity 测试; `test_render_parity.py` 共 15 个用例, 覆盖多轮对话、tools (`strict`、`defer_loading`、`extra`)、`tool_choice` (`auto`/`none`/`required`)、`reasoning_effort`、`enable_thinking` 与 `template kwargs`。

关键文件:

- `tests/entrypoints/openai/test_render_parity.py` (模块 渲染测试; 类别 test; 类型 test-coverage; 符号 `MockHFConfig`, `MockModelConfig`, `get_diff_sampling_param`, `CapturedRenderInputs`): 新增 479 行跨 API 渲染一致性测试, 是本次变更的核心资产: `RenderCapture` 在 `render_chat_async` 边界捕获输入, `_assert_parity` 对两套 API 的 `messages` 与 `ChatParams` 逐字段断言, 驱动了全部 bugfix。
- `vllm/entrypoints/openai/responses/utils.py` (模块 响应处理; 类别 source; 类型 core-logic; 符号 `convert_tool_responses_to_completions_format`, `construct_tool_dicts`): 核心修复所在: `convert_tool_responses_to_completions_format` 改为构造 `ChatCompletionToolsParam`, `construct_tool_dicts` 增加 `exclude_tools_when_tool_choice_none` 参数, 直接决定工具 schema 如何进入渲染管线。
- `tests/entrypoints/openai/responses/test_responses_utils.py` (模块 响应测试; 类别 test; 类型 test-coverage; 符号 `test_convert_tool_responses_to_completions_format`): 删除旧的裸 dict 断言用例, 说明转换逻辑的覆盖职责转移到了新的 parity 测试。
- `vllm/entrypoints/openai/responses/serving.py` (模块 响应服务; 类别 source; 类型 core-logic; 符号 `_make_request`): `_make_request` 将

exclude_tools_when_tool_choice_none 从 OnlineRenderer 透传给 construct_tool_dicts, 是 tool_choice='none' 语义对齐的调用侧关键改动。

- vllm/entrypoints/openai/engine/protocol.py (模块 协议模型; 类别 source; 类型 core-logic; 符号 FunctionDefinition._serialize) : FunctionDefinition._serialize 增加 model_fields 白名单过滤, 是 extra 字段被统一忽略的实现来源之一。
- vllm/entrypoints/openai/chat_completion/protocol.py (模块 对话协议; 类别 source; 类型 core-logic; 符号 ChatCompletionToolsParam._serialize) : ChatCompletionToolsParam._serialize 同步增加白名单过滤, 保证与 FunctionDefinition 行为一致, 是 extra 字段行为对称性的另一半。
- vllm/tool_parsers/utils.py (模块 工具解析; 类别 source; 类型 core-logic; 符号 iter_response_function_tool_dicts) : iter_response_function_tool_dicts 收紧为仅处理 FunctionTool, 修复类型泄漏但暴露 MCP 工具渲染缺口, 是 review 讨论的焦点。
- tests/entrypoints/openai/responses/test_parsable_context.py (模块 上下文测试; 类别 test; 类型 test-coverage; 符号 test_mcp_tool_call) : 为 MCP 工具调用测试增加 xfail 标记, 记录 ParsableContext 路径尚未支持 MCP 工具渲染的已知缺口。

关键符号: convert_tool_responses_to_completions_format, construct_tool_dicts, iter_response_function_tool_dicts, FunctionDefinition._serialize, ChatCompletionToolsParam._serialize, _make_request, _assert_parity, RenderCapture.take, test_multiturn_tool_calling

关键源码片段

tests/entrypoints/openai/test_render_parity.py

新增 479 行跨 API 渲染一致性测试, 是本次变更的核心资产: RenderCapture 在 render_chat_async 边界捕获输入, _assert_parity 对两套 API 的 messages 与 ChatParams 逐字段断言, 驱动了全部 bugfix。

```
class RenderCapture:
    """在 render_chat_async (HF 渲染边界) 安装桩, 记录其收到的输入。"""

    def __init__(self, online_renderer: OnlineRenderer) -> None:
        self.online_renderer = online_renderer
        self.captured: CapturedRenderInputs | None = None

    async def fake_render_chat_async(
        conversations, chat_params, tok_params=None, *,
        prompt_extras=None, skip_mm_cache=False,
    ):
        # 两条 API 路径最终都应只产生一组对话;
        # 记录消息与 ChatParams, 再返回一个假 token 输入即可走完流程。
        assert len(conversations) == 1
        self.captured = CapturedRenderInputs(
            messages=list(conversations[0]),
            chat_params=chat_params,
        )
```

```

        return [list(conversations[0])], [tokens_input(prompt_token_ids=[0])]

online_renderer.renderer.render_chat_async = fake_render_chat_async

def take(self) -> CapturedRenderInputs:
    # 取走当前捕获并复位，保证每次调用只消费一次观测结果。
    assert self.captured is not None
    captured = self.captured
    self.captured = None
    return captured

async def _assert_parity(
    online_renderer: OnlineRenderer,
    serving: OpenAIServingResponses,
    *,
    chat_kwargs: dict[str, Any],
    responses_kwargs: dict[str, Any],
) -> None:
    """构造配对请求，分别捕获两个 API 的 HF 渲染输入，再断言完全相等。"""
    chat_req = ChatCompletionRequest(model=_MODEL, **chat_kwargs)
    responses_req = ResponsesRequest(model=_MODEL, **responses_kwargs)
    chat = await _capture_chat(online_renderer, chat_req)
    responses = await _capture_responses(serving, responses_req)

    # 消息本身必须一致，工具转换的差异会在这里直接暴露。
    assert chat.messages == responses.messages

    # 模板相关字段逐一对比：template、content format、媒体参数、
    # template kwargs（含 tools），全部相等才算渲染一致。
    chat_params = chat.chat_params
    responses_params = responses.chat_params
    assert chat_params.chat_template == responses_params.chat_template
    assert (
        chat_params.chat_template_content_format
        == responses_params.chat_template_content_format
    )
    assert chat_params.media_io_kwargs == responses_params.media_io_kwargs
    assert chat_params.mm_processor_kwargs == responses_params.mm_processor_kwargs
    assert dict(chat_params.chat_template_kwargs) == dict(
        responses_params.chat_template_kwargs
    )

```

vllm/entrypoints/openai/responses/utils.py

核心修复所在：convert_tool_responses_to_completions_format 改为构造 ChatCompletionToolsParam，construct_tool_dicts 增加 exclude_tools_when_tool_choice_none 参数，直接决定工具 schema 如何进入渲染管线。

```
def convert_tool_responses_to_completions_format(
```

```

    tool: dict,
) -> ChatCompletionToolsParam:
    """
    将 Responses API 的扁平工具 schema:
        {"type": "function", "name": "...", "description": "...", "parameters": {...}}
    转换为 Chat Completions 工具参数，供 chat-template 渲染使用。

    关键点：直接构造 ChatCompletionToolsParam 而不是返回裸 dict，
    从而复用 Chat Completions 侧的字段校验与序列化逻辑，
    保证两种 API 渲染时工具 schema 完全一致。
    """
    return ChatCompletionToolsParam(
        type="function",
        # 丢弃 `type` 键，其余字段交给 FunctionDefinition 严格校验，
        # 未知的 extra 字段会被 pydantic 白名单序列化过滤，
        # 与 Chat Completions 的渲染行为保持一致。
        function=FunctionDefinition.model_validate(
            {k: v for k, v in tool.items() if k != "type"}
        ),
    )

```

```

def construct_tool_dicts(
    tools: list[Tool],
    tool_choice: ToolChoice,
    exclude_tools_when_tool_choice_none: bool = False,
) -> list[dict[str, Any]] | None:
    # tool_choice="none" 时是否仍把工具注入 prompt 取决于服务端参数，
    # 与 Chat Completions 的 --exclude-tools-when-tool-choice-none 对齐。
    if not tools or (tool_choice == "none" and exclude_tools_when_tool_choice_none):
        return None
    return [
        convert_tool_responses_to_completions_format(tool).model_dump()
        for tool in iter_response_function_tool_dicts(tools)
    ]

```

评论区精华

核心讨论围绕 vllm/tool_parsers/utils.py 中 iter_response_function_tool_dicts 由 else 改为 elif isinstance(tool, FunctionTool) 引发的回归：code_interpreter 等 MCP 工具不再被注入，导致 tests/entrypoints/openai/responses/test_parsable_context.py::test_mcp_tool_call 断言失败（期望 mcp_call 出现在输出中，实际只有 reasoning 与 message）。yzong-rh 说明 MCP 工具在 ParsableContext 路径上从未被正确支持：旧路径只是注入一个无 name/parameters 的非法 function tool，新路径则完全不注入，属于 "从坏的变成没有"；他提出两个方案——xfail 该测试，或继续 dump 非 function 工具以保留旧行为。bbrowning 赞同 xfail 是正确做法，并指出 xfail 有助于未来在 ParsableContext 完善时清理。此外 bbrowning 在 approve 评论中认可测试套件对拦截这类回归的价值，并补充运行了 tool_parsers、responses 等一组周边单测确认无回归。

- 非 function 工具注入回归与 MCP 工具缺口 (correctness): 采纳 xfail 方案: 对 test_mcp_tool_call 加 xfail 并在 reason 中注明 MCP 工具名与参数未被提取, 留待 ParsableContext 完善后再清理。
- 渲染一致性测试作为回归护栏 (testing): 无条件合入, 无未解决疑虑。

风险与影响

- 风险: 1) 行为变更风险: FunctionTool 与 ChatCompletionToolsParam 的 extra 字段现在会被 pydantic 静默丢弃 (engine/protocol.py 与 chat_completion/protocol.py 的序列化器新增 model_fields 白名单过滤), 依赖自定义扩展字段的工具方可能收到与之前不同的渲染结果, 且是静默丢弃而非报错。2) tool_choice='none' 语义变化: Responses API 默认将全部工具注入 prompt, prompt 变长会推高 token 消耗与 TTFT, 依赖 --exclude-tools-when-tool-choice-none 才能恢复旧行为。3) MCP 工具缺口只是被 xfail 掩蔽: ParsableContext 路径下 MCP 工具仍无法在 prompt 中渲染, 真实场景会静默缺少 mcp_call 输出, 存在回归风险。4) 测试机制局限: RenderCapture 拦截的是 render_chat_async 边界, 真实 HF 模板渲染、TokenizeParams、截断等不在覆盖范围, parity 测试全绿不代表端到端输出逐字节一致。
- 影响: 影响范围集中在 OpenAI 前端 API (Responses 与 Chat Completions 的工具渲染路径), 不涉及推理内核与调度器。对用户: Responses API 的 tool_choice='none' 默认行为变化、extra 字段被忽略, 属于可感知的行为变更; 对团队: 新增的 parity 测试为两个 API 的后续演进提供回归护栏, 避免渲染再次分叉; 对 API 实现者: FunctionDefinition 序列化现在按 model_fields 白名单输出, 限制未知字段传导到模板, 工具 schema 传递路径被显著收紧。
- 风险标记: 行为变更: extra 字段静默丢弃, 行为变更: tool_choice=none 默认注入工具, MCP 工具缺口仅 xfail 掩蔽, 测试覆盖渲染边界而非端到端输出

关联脉络

- PR #49824 FunctionTool not rendered identically to ChatCompletionToolsParam (PR #50334 body 引用): PR body 明确说明本 PR 的第一个 bugfix (FunctionTool 渲染不一致) 源于该 PR 的讨论, BFCL 端到端验证也挂在其上。
- PR #50515 [ROCM][CI] Restore Mistral tool-parser compatibility after unification: 同属 vllm/tool_parsers 路径的兼容性回归修复, 说明工具渲染路径近期正在统一与收敛, 本 PR 的 elif isinstance 收紧是该方向的一部分。
- PR #50491 [Bugfix][Frontend] Raise VLLMValidationError for user-facing errors in chat_utils.py: 同属 OpenAI 前端用户可见行为对齐工作, 反映 frontend API 行为一致性治理的大方向。