

PR #44330 完整报告

vllm-project/vllm

[Bugfix] GPT-OSS instruction rendering

合并时间: 2026-06-06 01:52

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/44330>

执行摘要

- 一句话: 修复 GPT-OSS 指令渲染与 HF 模板不一致
- 推荐动作:
 - 值得精读: 特别是 `build_harmony_preamble` 的设计和如何通过 `extract_instructions_from_messages` 抽象消息预处理逻辑。
 - 关注测试: 四个 case 的渲染对比示例是验证行为的好材料。
 - 留意环境变量: `VLLM_GPT_OSS_HARMONY_SYSTEM_INSTRUCTIONS` 的行为需在部署时确认。

功能与动机

根据 issue #33210, GPT-OSS 的指令渲染与 HF 的 `apply_chat_template` 不一致: vLLM 总是插入一个默认的 `developer` 消息, 且用户的 `system/developer` 消息作为单独的消息放在后面。本 PR 修复此问题, 将第一个 `system/developer` 指令消息折叠到 `preamble` 的 `developer` 块中, 并确保在无指令无工具时跳过 `developer` 块。

实现拆解

1. 新增 `extract_instructions_from_messages` 函数 (位于 `harmony_utils.py`) : 从消息列表中分离出首条 `system/developer` 消息的文本内容, 并返回剩余消息列表。
2. 新增 `build_harmony_preamble` 函数 (位于 `harmony_utils.py`) : 构建包含 `system` 消息和 `developer` 消息的 `preamble`, 将指令、工具描述、浏览器 / 代码解释器等内置工具描述合并到 `developer` 块中。
3. 改造 Chat Completions 入口 (`render/serving.py` 的 `_make_request_with_harmony`) : 原逻辑固定创建 `system` 消息 + 可选的 `developer` 消息 (仅当有工具时)。现改为调用 `extract_instructions_from_messages` 并传入 `build_harmony_preamble`, 使首条 `system/developer` 指令自然融入 `preamble`。
4. 改造 Responses API 入口 (`responses/serving.py` 的 `_construct_input_messages_with_harmony`) : 类似地, 先尝试从 `request.instructions` 获取指令, 否则从 `request.input` 中提取首条指令消息, 再调用 `build_harmony_preamble`。原冗长的 `_construct_harmony_system_input_message` 被拆分为更轻量的 `_get_harmony_builtin_tool_descriptions`。

5. 统一消息转换逻辑 (`responses/harmony.py` 的 `_parse_chat_format_message` 和 `response_input_to_harmony`) : 将 system/developer 消息统一转换为带有 `DeveloperContent` 的消息, 通过 `get_system_or_developer_message` 根据环境变量 `VLLM_GPT_OSS_HARMONY_SYSTEM_INSTRUCTIONS` 决定使用 system 还是 developer 角色。
6. 配套测试: 新增 `test_system_message_without_tools` 和 `test_system_message_with_tools` 验证 Chat Completions 路径; 更新 `test_response_input_to_harmony.py` 中 developer 消息的预期输出; 添加 `test_developer_message` 到渲染测试中。

关键文件:

- `vllm/entrypoints/openai/parser/harmony_utils.py` (模块 入口解析; 类别 source; 类型 dependency-wiring; 符号 `get_system_or_developer_message`, `flatten_input_text_content`, `extract_instructions_from_messages`, `build_harmony_preamble`) : 核心 utils, 新增 `extract_instructions_from_messages`, `build_harmony_preamble` 等关键函数, 重构消息预处理逻辑
- `vllm/entrypoints/openai/responses/serving.py` (模块 入口层; 类别 source; 类型 core-logic; 符号 `_get_harmony_builtin_tool_descriptions`, `_construct_input_messages_with_harmony`) : Responses API 入口重构, 提取指令和工具描述逻辑, 使用新的 `build_harmony_preamble`
- `vllm/entrypoints/openai/responses/harmony.py` (模块 入口层; 类别 source; 类型 core-logic; 符号 `_parse_chat_format_message`, `response_input_to_harmony`) : 统一 system/developer 消息转换为 `DeveloperContent`, 使用新工具函数
- `vllm/entrypoints/serve/render/serving.py` (模块 入口层; 类别 source; 类型 core-logic; 符号 `_make_request_with_harmony`) : Chat Completions 入口使用新的 `extract_instructions + build_harmony_preamble` 替换原有直接创建 system/developer 消息
- `tests/entrypoints/openai/chat_completion/test_serving_chat.py` (模块 对话服务; 类别 test; 类型 test-coverage; 符号 `test_system_message_without_tools`, `test_system_message_with_tools`) : 新增 `test_system_message_without_tools` 和 `test_system_message_with_tools` 验证 system 消息正确折叠
- `tests/entrypoints/openai/responses/test_response_input_to_harmony.py` (模块 响应解析; 类别 test; 类型 test-coverage; 符号 `test_system_message`, `test_developer_message_gets_instructions_prefix`, `test_developer_message_array_content_concatenated`) : 更新 developer 消息的预期输出: 使用 `DeveloperContent` 而非文本前缀
- `tests/entrypoints/openai/parser/test_harmony_render_parity.py` (模块 测试对齐; 类别 test; 类型 test-coverage; 符号 `test_developer_message`) : 新增 `test_developer_message` 验证渲染与 HF 一致
- `tests/entrypoints/openai/parser/test_harmony_utils.py` (模块 测试工具; 类别 test; 类型 test-coverage) : 适配 `extract_instructions_from_messages` 和 `flatten_input_text_content` 的改动

- tests/entrypoints/openai/utils.py (模块 测试公用; 类别 test; 类型 test-coverage) : 辅助测试文件, 增加对 DeveloperContent 的校验支持

关键符号: get_system_or_developer_message, flatten_input_text_content, extract_instructions_from_messages, build_harmony_preamble, _construct_input_messages_with_harmony, _make_request_with_harmony, _parse_chat_format_message, response_input_to_harmony

关键源码片段

vllm/entrypoints/openai/parser/harmony_utils.py

核心 utils, 新增 extract_instructions_from_messages、build_harmony_preamble 等关键函数, 重构消息预处理逻辑

harmony_utils.py — 新增的核心函数

```
def extract_instructions_from_messages(
    messages: Sequence[Any],
) -> tuple[str | None, list[Any]]:
    """
    从消息列表中分离出首条 system/developer 消息的文本内容。
    返回 (指令文本, 剩余消息列表)。如果首条不是 system/developer, 返回 (None, messages)。
    """
    remaining_messages = list(messages)
    if not remaining_messages:
        return None, remaining_messages

    first_message = remaining_messages[0]
    if not isinstance(first_message, dict):
        if hasattr(first_message, "to_dict"):
            first_message = first_message.to_dict()
        elif hasattr(first_message, "model_dump"):
            first_message = first_message.model_dump(exclude_none=True)
        else:
            raise ValueError(f"Unknown message type: {type(first_message)}")

    if first_message.get("role") not in ("system", "developer"):
        return None, remaining_messages

    instructions = flatten_input_text_content(first_message.get("content"))
    return instructions, remaining_messages[1:]

def build_harmony_preamble(
    *,
    instructions: str | None = None,
    tools: list[Tool | ChatCompletionToolsParam] | None = None,
    reasoning_effort: str | None = None,
    browser_description: str | None = None,
```

```

python_description: str | None = None,
container_description: str | None = None,
with_custom_tools: bool = False,
) -> list[Message]:
    """
    构建 Harmony 请求的 preamble: system 消息 + 可选的 developer
    消息（包含指令和工具描述）。
    如果既没有 instructions 也没有 tools，且无内置工具，则只返回 system 消息。
    """
    sys_msg = get_system_message(
        reasoning_effort=reasoning_effort,
        browser_description=browser_description,
        python_description=python_description,
        container_description=container_description,
        with_custom_tools=with_custom_tools,
    )
    # 只有当有指令或工具时才添加 developer 消息
    if instructions or tools or browser_description or python_description or container_description:
        dev_msg = get_developer_message(
            instructions=instructions,
            tools=tools,
        )
        return [sys_msg, dev_msg]
    return [sys_msg]

```

vllm/entrypoints/openai/responses/serving.py

Responses API 入口重构，提取指令和工具描述逻辑，使用新的 build_harmony_preamble

responses/serving.py — _construct_input_messages_with_harmony 关键重构部分

```

def _construct_input_messages_with_harmony(
    self,
    request: ResponsesRequest,
    prev_response: ResponsesResponse | None,
) -> list[OpenAIHarmonyMessage]:
    messages: list[OpenAIHarmonyMessage] = []
    request_input = request.input

    if prev_response is None:
        # 新的对话：提取指令，构建 preamble
        tool_types = extract_tool_types(request.tools)
        with_custom_tools = has_custom_tools(tool_types)

        instructions = request.instructions
        if instructions is None and isinstance(request_input, list):
            # 从 input 中提取首条 system/developer 消息作为指令
            instructions, request_input = extract_instructions_from_messages(request_input)

        tool_descriptions = self._get_harmony_builtin_tool_descriptions(request, tool_types)

```

```

# 构建 Harmony preamble (system + developer 消息)
preamble = build_harmony_preamble(
    instructions=instructions,
    tools=request.tools if with_custom_tools else None,
    browser_description=tool_descriptions["browser_description"],
    python_description=tool_descriptions["python_description"],
    container_description=tool_descriptions["container_description"],
    with_custom_tools=with_custom_tools,
)
messages.extend(preamble)

# 转换剩余的输入消息 (已去除首条指令消息)
messages.extend(response_input_to_harmony_list(request_input))
else:
    # 已有对话: 直接转换所有消息
    messages = response_input_to_harmony_list(request_input)
    messages = construct_harmony_previous_input_messages(prev_response, messages)
return messages

```

评论区精华

reviewer bbrowning 在简化 review 中表示“同意与官方 chat template 对齐，因为模型供应商的 apply_chat_template 是事实标准”，并感谢 PR 描述中的 side-by-side 对比帮助理解变更影响。没有其他争议讨论。

- Review 批准和对齐 HF 的讨论 (other): 无争议，直接合并。

风险与影响

- 风险:
 - 渲染行为变化: 现有依赖原始渲染格式的客户端可能受到影响，但新行为更接近 HF 预期，属于修复性变更。
 - 环境变量依赖: VLLM_GPT_OSS_HARMONY_SYSTEM_INSTRUCTIONS 控制是否使用 system 角色，如果用户依赖该变量但未更新部署，可能导致意外行为。测试已覆盖两种模式。
 - 工具折叠逻辑: 工具描述与指令合并到同一 developer 块，若工具列表为空则无 developer 块，可能改变已有工具调用的输出格式。但该逻辑与 HF 保持一致。
 - Responses API 路径: _construct_input_messages_with_harmony 重构后，request.instructions 优先级高于从 input 提取，可能影响使用指令的客户端。但这是明确的设计选择，文档已更新。
- 影响:
 - 用户影响: 所有使用 GPT-OSS 模型的 Chat Completions 和 Responses API 用户。生成的消息序列改变，但对齐 HF 后模型输出质量有望提升。
 - 系统影响: 无性能影响；改动集中在入口解析层，不涉及核心引擎。
 - 团队影响: 维护者需注意未来新增模型时遵循此模式。

- 风险标记：渲染逻辑变更，环境变量依赖，工具折叠逻辑，Responses API 重构

关联脉络

- 暂无明显关联 PR