

PR #47189 完整报告

vllm-project/vllm

[Frontend] Cohere chat v2 api support

合并时间: 2026-08-01 13:53

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/47189>

执行摘要

- 一句话: 新增 Cohere Chat v2 API 前端支持与 citations 渲染
- 推荐动作: 值得精读。该 PR 是 vLLM 前端协议扩展的范例: 通过子类化保持既有 OpenAI schema 稳定、以中间件统一外部 API 错误信封、用 env 门控控制新端点暴露面, 以及用构造器钩子避免复制分支逻辑。建议关注 `api_router.py` 的错误翻译中间件、`serving.py` 的 SSE 状态机与 `cohere_chat_message.py` 的序列化技巧; 同时提醒排查 `/cohere` 未纳入认证前缀的安全遗留问题。

功能与动机

RFC #43015 提出 vLLM 目前不支持 Cohere 的 `/v2/chat` HTTP API, 而该 API 拥有 citations、thinking、tool_plan 等独特字段, 重要用户希望直接对 vLLM 服务 Cohere 模型。RFC 建议仿照 `create_chat_completion` 流程增加 `/cohere/v2/chat` 入口, 用 Melody 库完成 prompt 渲染, 并保留已有的输出解析逻辑; 本 PR 即按此路径落地。

实现拆解

1. 协议与数据契约: 新增 `vllm/entrypoints/cohere/protocol.py`, 复用官方 cohere SDK 的 `ChatMessageV2`、`ToolV2`、`Document`、`Citation` 等 wire 类型, 本地只维护 `CohereChatV2Request`、非流式响应信封 `CohereChatV2Response` 和流式事件类型。通过 `field_validator` 完成 `developer` -> `system` 角色归一化、`max_tokens` 非负校验和 `messages` 非空校验; `CohereError` 统一为 `{message, id}` 结构。
2. 路由与门控: 新增 `vllm/entrypoints/cohere/api_router.py`, 模块加载时探测 cohere SDK, `attach_router` 同时受 `VLLM_ENABLE_COHERE_API=1` 与 SDK 可用性双重门控; 未开启时跳过注册且区分 `DEBUG`/`WARNING` 日志。`chat_v2 handler` 返回三态: `ErrorResponse` 翻译为 `CohereError`、`CohereChatV2Response` 输出 JSON、其余视为 SSE 流。`CohereErrorEnvelopeMiddleware` 把全局异常处理器产生的 vLLM `ErrorResponse` 体改写为 Cohere 错误形状, 保证 OpenAPI responses 与线上行为一致。
3. 服务层转换: 新增 `vllm/entrypoints/cohere/serving.py`, `CohereServingChatV2` 继承 `OpenAIServingChat`, `create_chat_v2` 先经 `_convert_v2_to_chat_completion` 转换消息、`tools`、`response_format`、`stream` 选项, 并把 Cohere 特有的 `documents` / `safety_mode` / `citation_options` / `thinking` 通过 `chat_template_kwargs` 透传给渲染器; 非流式响应完成 `finish_reason`、`usage` 映射, 流式响应用 `_StreamState` 状态机生成 `message-start/content-start/content-delta/citation` 事件并以 `[DONE]` 结束。

4. 渲染器：新增 `vllm/renderers/cohere.py`, `CohereRenderer` 用 `cohere_melody` Rust 绑定渲染 `cmd3 / cmd4` 模板，统一来自 `CohereServingChatV2` 与直接 `chat_template_kwargs` 调用者的两套词汇；`_role_to_melody` 完成 `assistant -> chatbot`、`developer -> system` 映射，`_normalize_tool_call` 把 OpenAI 工具调用转成 `melody` 的 `{id, name, parameters}` 形状，并在 `_build_render_config` 中拒绝 `template_jinja / template` 直传。
5. 消息扩展与推理解析：新增 `vllm/entrypoints/cohere/cohere_chat_message.py`, 用 `CohereChatMessage / CohereDeltaMessage` 子类承载 `citations` 字段，序列化时剥离空 `citations`；`vllm/reasoning/cohere_command_reasoning_parser.py` 通过 `POSITION_TO_SOURCE_KEY` 与 `MESSAGES_CITATIONS_KEY` 把 `melody` 数值坐标解析成真实 `document/tool source`，并生成对应 `citation`。
6. 配套改动：`OpenAIServingChat` 增加 `_create_chat_message` 构造钩子，`ChatCompletionResponseChoice` 等改用 `SerializeAsAny[ChatMessage]`；`vllm/envs.py` 注册 `VLLM_ENABLE_COHERE_API`，CLI 增加 `--cohere-is-reasoning-model` 等参数；测试覆盖单元层（`protocol`、`conversion`、`streaming`、`renderer`、`router`）与 E2E 层（轻量 `SmolLM2-135M-Instruct` 起真实 `server`，含 `Cohere SDK` 回环）。

关键文件：

- `vllm/entrypoints/cohere/api_router.py`（模块 请求路由；类别 `source`；类型 `entrypoint`；符号 `attach_router`, `chat_v2`, `CohereErrorEnvelopeMiddleware`, `_translate_vllm_error_body`）：新增 `/cohere/v2/chat` 的注册与门控逻辑：模块加载时探测 `cohere SDK`，`attach_router` 同时受 `VLLM_ENABLE_COHERE_API` 控制；路由 `handler` 负责把 `vLLM` 内部 `ErrorResponse` 翻译成 `CohereError`，并用中间件兜底全局异常。
- `vllm/entrypoints/cohere/serving.py`（模块 服务层；类别 `source`；类型 `core-logic`；符号 `CohereServingChatV2`, `create_chat_v2`, `_convert_v2_to_chat_completion`, `_chat_completion_to_v2`）：核心服务层：`CohereServingChatV2` 继承 `OpenAIServingChat`，负责 `v2` 请求到 `ChatCompletionRequest` 的转换、非流式响应映射、`SSE` 流状态机（`_StreamState`）以及 `citations` 的 `wire` 形状转换。
- `vllm/entrypoints/cohere/protocol.py`（模块 协议层；类别 `source`；类型 `data-contract`；符号 `CohereChatV2Request`, `CohereChatV2Response`, `CohereError`, `CohereFinishReason`）：协议契约：复用 `cohere SDK` 各消息 / 工具 / 文档类型，本地只维护请求体、非流式响应信封和流式事件联合；包含 `developer->system` 的角色归一化与 `max_tokens` 校验。
- `vllm/renderers/cohere.py`（模块 渲染器；类别 `source`；类型 `core-logic`；符号 `CohereRenderer`, `_role_to_melody`, `_normalize_tool_call`, `_content_blocks`）：新增 `CohereRenderer`，用 `cohere_melody` Rust 绑定渲染 `cmd3/cmd4` 模板，统一来自 `CohereServingChatV2` 和直接 `chat_template_kwargs` 调用者的双词汇；安全拒绝 `template_jinja/template` 直传。
- `vllm/entrypoints/cohere/cohere_chat_message.py`（模块 消息扩展；类别 `source`；类型 `core-logic`；符号 `Citation`, `CitationSource`, `CohereChatMessage`, `CohereDeltaMessage`）：以子类方式为 `ChatMessage/DeltaMessage` 增加 `citations` 字段，并通过 `SerializeAsAny` 在响应信封中保留子类 `schema`，避免污染 `OpenAI` 协议。

- `vllm/entrypoints/openai/chat_completion/serving.py` (模块 服务层; 类别 `source`; 类型 `core-logic`; 符号 `_create_chat_message`, `_finalize_response_message`) : 为 `OpenAIServingChat` 增加 `_create_chat_message` 构造钩子并调整 `_finalize_response_message`, 使子类可以替换响应 `ChatMessage` 类型而不复制分支逻辑。
- `vllm/reasoning/cohere_command_reasoning_parser.py` (模块 推理解析; 类别 `source`; 类型 `core-logic`; 符号 `_melody_sources_to_vllm`, `_melody_citations_to_vllm`) : 推理解析器通过 `POSITION_TO_SOURCE_KEY` 和 `MESSAGES_CITATIONS_KEY` 把 `melody` 数值坐标解析成真实 `document/tool` 源, 并生成 `Citation/CohereDeltaMessage`。
- `tests/entrypoints/cohere/test_chat_v2.py` (模块 集成测试; 类别 `test`; 类型 `test-coverage`; 符号 `test_cohere_v2_chat_non_streaming`, `test_cohere_v2_chat_streaming`, `test_cohere_v2_chat_validation_error_returns_400`, `test_cohere_v2_chat_documents_field_accepted`) : E2E 集成测试: CPU 可跑的真实 `serve` 进程 + `httpx` 覆盖非流式 / 流式 / 校验错误 / `documents` 字段, 并用官方 `cohere SDK` 做回环; 验证路由、转换和 `SSE` 生命周期。

关键符号: `attach_router`, `chat_v2`, `CohereErrorEnvelopeMiddleware.dispatch`, `CohereServingChatV2.create_chat_v2`, `CohereServingChatV2._convert_v2_to_chat_completion`, `CohereServingChatV2._chat_completion_to_v2`, `CohereServingChatV2._chat_completion_stream_to_v2`, `CohereServingChatV2._apply_cohere_template_kwargs`, `CohereRenderer.render`, `_role_to_melody`, `_normalize_tool_call`, `CohereChatMessage._serialize`, `CohereDeltaMessage._serialize`, `CohereChatV2Request._normalize_message_roles`, `OpenAIServingChat._create_chat_message`, `_melody_sources_to_vllm`

关键源码片段

`vllm/entrypoints/cohere/serving.py`

核心服务层: `CohereServingChatV2` 继承 `OpenAIServingChat`, 负责 `v2` 请求到 `ChatCompletionRequest` 的转换、非流式响应映射、`SSE` 流状态机 (`_StreamState`) 以及 `citations` 的 `wire` 形状转换。

```
class CohereServingChatV2(OpenAIServingChat):
    """Cohere Chat v2 服务处理器。
```

```
    核心思路: 把 Cohere v2 请求先翻译成 OpenAIServingChat 能识别的
    ChatCompletionRequest, 再复用整条 chat completion 生成链路;
    Cohere 特有的 documents / safety_mode / citation_options 等字段
    通过 chat_template_kwargs 透传给渲染器。
```

```
    """
```

```
    async def create_chat_v2(
        self,
        request: CohereChatV2Request,
        raw_request: Request | None = None,
    ) -> AsyncGenerator[str, None] | CohereChatV2Response | ErrorResponse:
        # 先做 v2 -> OpenAI 的字段映射 (messages、tools、stream 等),
```

```

# 再整体下发，保持与 create_chat_completion 一致的行为。
chat_req = self._convert_v2_to_chat_completion(request)
generator = await self.create_chat_completion(chat_req, raw_request)

# 三种出口：内部错误原样返回；普通响应转成 Cohere v2 信封；
# 流式响应转成 message-start / content-* / message-end 事件序列。
match generator:
    case ErrorResponse():
        return generator
    case ChatCompletionResponse():
        return self._chat_completion_to_v2(generator, request)
    case _:
        return self._chat_completion_stream_to_v2(generator, request)

@classmethod
def _convert_v2_to_chat_completion(
    cls, request: CohereChatV2Request
) -> ChatCompletionRequest:
    # 逐条转换消息（user / assistant / system / tool），
    # 然后按功能分组调用子转换器，保持单一职责。
    openai_messages: list[dict[str, Any]] = []
    cls._convert_messages(request.messages, openai_messages)
    chat_req = cls._build_base_chat_completion(request, openai_messages)
    cls._apply_streaming_options(chat_req, request)
    cls._apply_response_format(chat_req, request)
    cls._apply_tools(chat_req, request)
    cls._apply_tool_choice(chat_req, request)
    cls._apply_cohere_template_kwargs(chat_req, request)
    return chat_req

```

vllm/entrypoints/cohere/cohere_chat_message.py

以子类方式为 ChatMessage/DeltaMessage 增加 citations 字段，并通过 SerializeAsAny 在响应信封中保留子类 schema，避免污染 OpenAI 协议。

```

class CitationSource(OpenAIBaseModel):
    """citation 的源归属（document / tool）。


由 Cohere 推理解析器在生成时就解析出真实 document / tool id，  
serving 层只负责转成 SDK 的 cohere.types.Citation。



"""



type: Literal['document', 'tool'] | None = None  
id: str | None = None  
document: dict[str, Any] | None = None  
tool_output: dict[str, Any] | None = None


```

```

class CohereChatMessage(ChatMessage):
    """带 citations 的 ChatMessage 子类。

```

只有 CohereServingChatV2 走这条路径；普通 OpenAI 响应仍是原版 ChatMessage，schema 不受影响。响应信封里声明了 `SerializeAsAny[ChatMessage]`，所以子类字段能保留到 JSON。

"""

`citations: list[Citation] | None = None`

```
@model_serializer(mode='wrap')
def _serialize(self, handler):
    # mode='wrap' 会整体覆盖父类的 model_serializer，因此显式
    # 调用 super()._serialize 保留父类清理逻辑（如剥离空 tool_calls）；
    # 再删掉未设置的 citations，让可选扩展省略而不是输出 null。
    data = super()._serialize(handler)
    if not data.get('citations'):
        data.pop('citations', None)
    return data
```

评论区精华

核心争论在于是否让 OpenAI 协议承载 Cohere 专属字段：DarkLight1337 认为不应为覆盖其他 API 而扩展 OpenAI 协议，建议抽取公共代码；作者改为 `ChatMessage` 子类 + `SerializeAsAny`，并承诺由 Cohere 承担维护。另一个争议是新端点默认暴露面：chaunceyjiang 建议新增端点必须默认关闭，最终引入 `VLLM_ENABLE_COHERE_API` 环境变量优化。depthfirst-app[bot] 提出 `chat_template_kwargs['template_jinja']` 绕过 `trust_request_chat_template` 的注入风险，最终渲染器拒绝非 None 直传。aarnphm 与 sfeng33 讨论 parser 的 `adjust_response` 钩子，认为应把 citations 元数据从 serving 类移出，属于非阻塞后续项。

- 是否将 citations 字段加入 OpenAI 协议 (design): 采用 CohereChatMessage/CohereDeltaMessage 子类 + SerializeAsAny 序列化，基础 ChatMessage/DeltaMessage schema 不变，由 Cohere 承担后续维护。
- 新端点默认开启还是 opt-in (design): /cohere/v2/chat 仅在 `VLLM_ENABLE_COHERE_API=1` 且安装 cohere SDK 时注册，默认不暴露。
- 认证保护缺失: /cohere 不在 GUARDED_PREFIX (security): PR 内未修改 server_utils.py；端点默认关闭缓解了暴露面，但开启后的认证覆盖问题未在本 PR 内解决，需后续跟进。
- chat_template_kwargs 的 template_jinja 注入面 (security): 渲染器最终把 template_jinja/template 纳入消费键集，并在 _build_render_config 拒绝非 None 值，注入面被收敛。
- parser 的 adjust_response 钩子 (design): 决定本 PR 不实施，Cohere 侧后续跟进；当前通过 _create_chat_message 钩子 + ChatMessage 子类解决。
- 疑似 AI 生成的冗余测试 (testing): 删除冗余测试，保留有区分度的用例。

风险与影响

- 风险：安全方面存在两个关注点：一是 /cohere/v2/chat 不在 AuthenticationMiddleware 的 GUARDED_PREFIX (/v1、/v2、/inference) 内，若运维开启

VLLM_ENABLE_COHERE_API 且配置 --api-key，该端点可能未受认证保护；本 PR 未修改 server_utils.py，需后续跟进。二是 chat_template_kwargs 由用户控制，虽然 template_jinja 已被拒绝，但 setdefault 允许用户覆盖 documents 等字段只影响自身请求，风险可控。兼容性方面，OpenAIServingChat 新增 _create_chat_message 钩子并调整 _finalize_response_message，默认返回值不变，但对带 reasoning 的输出路径有轻微改动，需要依赖输出形状的调用方注意。流式转换的 _StreamState 状态机复杂度高，若 thinking 与 tool_call 交错出现而块未正确闭合，可能产生非法事件序列，已有单测覆盖但仍需真实模型验证。

- 影响：对用户：使用 Cohere Command 系列模型的用户可直接调用 /cohere/v2/chat，获得 citations、thinking、工具调用等原生语义；非 Cohere 部署默认不受影响。对系统：端点默认关闭，只有显式设置 VLLM_ENABLE_COHERE_API=1 且安装 cohere SDK 时才注册路由与中间件；中间件只作用于 /cohere/* 前缀的错误响应，不影响其他 API。对团队：OpenAI serving 层新增一个扩展点，后续其它非 OpenAI 协议可复用，但 OpenAI 协议也由此引入了 SerializeAsAny 的子类序列化机制，schema 复杂度小幅上升；Cohere 侧承诺跟进 parser adjust_response 等后续重构。
- 风险标记：认证前缀遗漏待跟进，OpenAI 核心服务钩子变更，SSE 状态机复杂度高，可选依赖缺失时入口静默关闭，模板注入面已收敛

关联脉络

- PR #50334 [Bugfix][Responses] Add tests for Chat Completions Responses API
Render Parity: 同属前端协议与渲染一致性工作线，涉及 ChatMessage 序列化、工具渲染和 API 间 parity 测试，与本 PR 的渲染器与消息扩展改动相互印证。
- PR #50642 [Bugfix][Parser] Forward model_config to nested reasoning parsers: 与 vllm/reasoning 解析器相关，本 PR 同样调整了 Cohere 推理解析器的 source/citation 解析逻辑。
- PR #50515 [ROCm][CI] Restore Mistral tool-parser compatibility after unification: 同样触及前端工具解析与 OpenAI serving 层，体现工具调用路径的持续演进。