

PR #50515 完整报告

vllm-project/vllm

[ROCm][CI] Restore Mistral tool-parser compatibility after unification

合并时间: 2026-08-01 00:32

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/50515>

执行摘要

- 一句话: 修复 Mistral 工具解析器统一后的兼容性回归
- 推荐动作: 值得快速精读。这是统一重构后兼容性适配的典型修复样例: 通过 adapter 属性转发恢复嵌套 engine 的对外契约, 并通过显式 None 分支保留旧路径的可空 request 语义。评审中「getattr 兜底 vs 显式 None 检查 + 类型标注同步修改」的取舍值得借鉴。若后续有同类 parser 统一工作, 应参考本 PR 补充针对 request=None 与属性转发的单元测试。

功能与动机

PR body 通过 git bisect 定位到 PR #48947 是首次引入该失败的修订: 统一 parser 将 bot_token 和 bot_token_id 移到了嵌套 engine 上, 而既有调用方仍在适配器上访问它们; 同时 _legacy_extract_tool_calls 直接访问 request.tool_choice 和 request.tools, 但既有 parser API 允许 request=None 且旧实现容忍这一点。回归由 AMD CI build 11504 的 Language Models Test (Extended Generation) 暴露。

实现拆解

1. 恢复适配器属性暴露 (vllm/tool_parsers/mistral_tool_parser.py): 在 MistralToolParser 上以 @property 形式重新定义 bot_token 与 bot_token_id, 直接转发到 self._parser_engine, 使统一 parser 后仍可在适配器层读取 Mistral 工具调用标记及其 token id, 恢复旧 MistralToolParser 的对外契约。
2. 放宽 _legacy_extract_tool_calls 的 request 可空性 (vllm/parser/mistral.py): 将参数类型从 ChatCompletionRequest 改为 ChatCompletionRequest | None, 在函数开头显式分支解包 tool_choice 与 tools 为局部变量, 后续判断统一改用局部变量, 避免 request 为 None 时访问属性抛 AttributeError。
3. 配套验证: 本 PR 未新增单元测试, 回归验证依赖 AMD ROCm CI 的 Extended Generation 测试; review 中评审者建议放弃 getattr 兜底写法、改为显式 None 检查并同步修改类型标注, 作者已在第二个 commit 中采纳。

关键文件:

- vllm/tool_parsers/mistral_tool_parser.py (模块 工具解析; 类别 source; 类型 core-logic; 符号 bot_token, bot_token_id): 在统一 parser 的适配器层恢复 bot_token / bot_token_id 属性并转发至嵌套 engine, 是修复调用方属性访问失败的关键入口。

- `vllm/parser/mistral.py` (模块 解析引擎; 类别 `source`; 类型 `core-logic`; 符号 `_legacy_extract_tool_calls`): `_legacy_extract_tool_calls` 放宽为可空 `request` 并显式处理 `None` 分支, 是恢复旧解析器对 `request=None` 容忍度的核心逻辑改动。

关键符号: `bot_token`, `bot_token_id`, `_legacy_extract_tool_calls`,
`extract_tool_calls_from_content`

关键源码片段

`vllm/tool_parsers/mistral_tool_parser.py`

在统一 `parser` 的适配器层恢复 `bot_token` / `bot_token_id` 属性并转发至嵌套 `engine`, 是修复调用方属性访问失败的关键入口。

```
class MistralToolParser(MistralParserToolAdapter):
    # 统一 parser 重构后, bot_token / bot_token_id 只存在于嵌套的 parser engine 上,
    # 而既有调用方仍在适配器层访问这两个属性, 因此必须显式转发以恢复旧行为。
    IS_MISTRAL_TOOL_PARSER = True

    # Mistral 以 [TOOL_CALLS]name[ARGS]{...} 格式输出工具调用,
    # 与 serving 层通用 required / named handler 期望的 JSON 数组格式不同,
    # 因此把 required / named 也路由到本解析器的提取逻辑 (按 auto 处理),
    # 避免解析崩溃或把原始信封直接灌进 arguments。
    supports_required_and_named = False

    @property
    def bot_token(self) -> str:
        """返回旧版解析器暴露的 Mistral 工具调用标记。"""
        return self._parser_engine.bot_token

    @property
    def bot_token_id(self) -> int | None:
        """返回 bot_token 对应的 token id; tokenizer 未提供时为 None。"""
        return self._parser_engine.bot_token_id

    def adjust_request(
        self,
        request: ChatCompletionRequest | ResponsesRequest,
    ) -> ChatCompletionRequest | ResponsesRequest:
        # 跳过基类 tool_choice -> structured_outputs 转换:
        # Mistral 通过 grammar mode (auto / none / required / named) 强制 tool_choice,
        # 若把 tool 派生的 json_schema 并入 grammar, 会允许裸 JSON 混入,
        # 破坏真正的 [TOOL_CALLS] 调用格式。用户显式提供的结构化输出
        # 仍由 engine 的 adjust_request 处理。
        return self._parser_engine.adjust_request(request)
```

`vllm/parser/mistral.py`

`_legacy_extract_tool_calls` 放宽为可空 `request` 并显式处理 `None` 分支, 是恢复旧解析器对 `request=None` 容忍度的核心逻辑改动。

```

def _legacy_extract_tool_calls(
    self,
    model_output: str,
    request: ChatCompletionRequest | None,
) -> ExtractedToolCallInformation:
    """Pre-v11 非流式提取，处理 [TOOL_CALLS] 信封与受引导的裸数组格式。

    统一 parser 后调用方可能以 request=None 进入该路径（旧 MistralToolParser
    一直容忍这种用法），因此先显式解包，而不是直接访问
    request.tool_choice / request.tools 导致 AttributeError。
    """
    if request is None:
        tool_choice = None
        tools = None
    else:
        tool_choice = request.tool_choice
        tools = request.tools

    # tool_choice 为 "none" 且同时给出 tools 时，绝不产生工具调用。
    if tool_choice == "none" and tools:
        return ExtractedToolCallInformation(
            tools_called=False, tool_calls=[], content=model_output
        )

    content: str | None = None
    if self.bot_token in model_output:
        content_and_raw_tool_calls = model_output.split(self.bot_token)
        content = content_and_raw_tool_calls[0]
        raw_tool_calls = content_and_raw_tool_calls[1:]
        # pre-v11 格式: content[BOT][{tool_call1},{tool_call2}]
        if len(raw_tool_calls) != 1:
            raise ValueError(
                "Only one BOT token should have been outputted, "
                f"but got {model_output}."
            )
        stringified_tool_calls = raw_tool_calls[0].strip()
    elif tool_choice == "required" or isinstance(
        tool_choice, ChatCompletionNamedToolChoiceParam
    ):
        # 受引导的裸数组输出（没有 [TOOL_CALLS] 标记）。
        stringified_tool_calls = model_output.strip()
    else:
        return ExtractedToolCallInformation(
            tools_called=False, tool_calls=[], content=model_output
        )

```

评论区精华

juliendenize 评论指出：最初实现用 `getattr(request, "tool_choice", None)` 兜底显得有些奇怪，既然用例是让 `request` 可以为 `None`，不如显式检查 `request is None` 并修改类型标注。作者 AndreasKaratzas 回复 "Updated the two Mistral leaf signatures :)", 将两个叶函数签名更新为显式 `None` 分支，随后获得 mgoin 与 sfeng33 的 APPROVED。

- `_legacy_extract_tool_calls` 中 `request=None` 的处理方式 (design): 作者采纳建议，将两个 Mistral 叶函数签名更新为显式 `None` 分支，并修改参数类型为 `ChatCompletionRequest | None`。

风险与影响

- 风险：
 1. 缺少直接配套单测：本 PR 没有新增测试文件，回归保护完全依赖 AMD CI Extended Generation 测试，后续 parser 重构可能再次破坏该兼容性。
 2. `request` 可空性放宽的影响面：`_legacy_extract_tool_calls` 现在接受 `request=None` 并返回 `tools_called=False` 的兜底结果，若调用方误传入 `None` 可能掩盖真实的参数错误，但该行为与旧实现一致，属于恢复而非新语义。
 3. `bot_token_id` 返回类型为 `int | None`：若外部调用方此前假定非空，统一重构后可能出现类型感知差异，但本 PR 只是恢复旧行为。
 4. 改动仅在 `_is_pre_v11` 分支生效，`v11+` 路径走 `super().extract_tool_calls_from_content`，不受影响，整体回归风险可控。
 - 影响：影响范围集中在 Mistral 工具调用解析路径：修复 AMD ROCm CI 的 Extended Generation 测试回归，恢复 Mistral pre-v11 tokenizer 模型在工具调用场景下的正常解析（包括 [TOOL_CALLS] 信封格式与 `request` 可选场景）。对使用 `MistralToolParser` 的 serving 层调用方是正向兼容性恢复；对 `v11+` 解析路径无行为变化。团队层面消除了 AMD CI 的阻塞失败，属于小范围高价值修复。
 - 风险标记：缺少直接单元测试配套，依赖 AMD CI 回归验证，parser API 可空性放宽

关联脉络

- PR #48947 Unified Mistral tool parser engine: PR body 通过 `git bisect` 定位的回归源头：统一 parser 将 `bot_token` / `bot_token_id` 移到嵌套 engine，并让 `_legacy_extract_tool_calls` 假定 `request` 对象存在；本 PR 正是为恢复这两项行为而修复。