

PR #52246 完整报告

vllm-project/vllm

[Bugfix][Anthropic] Return 4xx for client-caused errors in /v1/messages

合并时间: 2026-08-16 16:05

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/52246>

执行摘要

- 一句话: Anthropic 入口将客户端错误统一映射为 4xx
- 推荐动作: 值得精读。这是一个小而完整的『入口错误处理对齐共享框架』示例: 评审推动作者放弃手写类型分支、复用 `create_error_response`, 最终以极小 diff 完成语义修复, 并配套了高质量回归测试 (用真实 `pydantic.ValidationError` 复现 Issue 场景)。对维护其他 `entrypoint` 的团队, 本 PR 展示了如何在共享异常框架演进时保持各入口一致, 值得作为参考模式。

功能与动机

Issue #52088 报告: CI 的 Schemathesis 测试生成的 Anthropic 请求可包含多于 4 个 `stop_sequences` (Anthropic 侧 schema 允许), 但 Anthropic→OpenAI 转换构造 `ChatCompletionRequest` 时抛出 `pydantic.ValidationError` (OpenAI `stop` 字段最多 4 项)。 `api_router` 的 `except Exception` 把该异常吞成 `internal_error` 导致 HTTP 500, 与 Issue 中『Invalid user input should not result in HTTP 500』的预期不符。PR body 明确指出 schema 半部分已由 #51997 解决, 本 PR 修复剩余的转换错误映射缺口。

实现拆解

1. 变更入口: `vllm/entrypoints/anthropic/api_router.py`。 `create_messages` 与 `count_tokens` 两个路由的异常分支从「手写 JSON 500 + `internal_error` 响应体」改为 `translate_error_response(create_error_response(e))`。 `create_error_response` 来自 `vllm/entrypoints/serve/exception_handling/error_response.py` (#52261 整合后的共享异常映射入口), 按异常类型分类: `pydantic.ValidationError` (`ValueError` 子类) 与 `VLLMClientError` 类客户端错误映射为 400 `BadRequestError`, 其余异常保持 500。 `translate_error_response` 负责把 OpenAI 风格 `ErrorResponse` 翻译成 Anthropic 错误格式 (`type + message`), 状态码沿用 `ErrorResponse.error.code`。同时删除对 `sanitize_message` 的直接 import——脱敏改由 `create_error_response` 内部完成。
2. 实现演进 (4 个 commit): 首版 (c90de82) 手写 `_translate_exception` 类型分支区分客户端错误; 评审 (DarkLight1337) 要求跟随 `server_utils.py` 的异常处理器逻辑; 第二版 (c21c8ed) 删除手写类型检查, 直接复用 `create_error_response`, 净 diff 收敛为 +6/-26, 并去掉不再使用的 `VLLMClientError/ValidationError` import; 第三版 (4bb117d) 按 AGENTS.md 精简冗余注释; 第四版 (90b3250) rebase 到 #52261 后修正两处测试。

3. 测试配套: `tests/entrypoints/anthropic/test_anthropic_messages_conversion.py`。新增 `TestClientErrorResponses` 类, 覆盖 4 个场景: 转换期 `ValidationError` → 400 且错误 type 为 `BadRequestError`、错误消息保留『at most 4 items』; `VLLMValidationError` → 400; `RuntimeError` → 500 (回归保护); `count_tokens` 路由 → 400。测试用 `_StubRequest (stop: Annotated[list[str], Field(max_length=4)] + 6 个元素)` 构造真实 `pydantic.ValidationError`, 与线上 `ChatCompletionRequest` 校验行为等价。
4. 配套调整: `tests/entrypoints/serve/exception_handling/test_error_sanitization.py`。
rebase 后 `api_router` 改为间接脱敏, 从『必须直接调用 `sanitize_message`』的源级检查参数化清单中移除 `vllm.entrypoints.anthropic.api_router`。
5. 无配置 `/schema/` 部署改动: 路由的 OpenAPI responses 本就声明 400/500 两类响应, 无需变更文档。

关键文件:

- `vllm/entrypoints/anthropic/api_router.py` (模块 请求路由; 类别 source; 类型 `entrypoint`; 符号 `create_messages`, `count_tokens`, `translate_error_response`, `attach_router`): PR 的核心改动文件: `create_messages` 与 `count_tokens` 两个路由的异常处理从手写 `internal_error 500` 改为复用共享 `create_error_response` 统一分类 (客户端 4xx、服务端 500), 并移除对 `sanitize_message` 的直接 import。
- `tests/entrypoints/anthropic/test_anthropic_messages_conversion.py` (模块 消息转换; 类别 test; 类型 test-coverage; 符号 `TestClientErrorResponses`, `_make_api_app`, `_request_body`, `_conversion_error`): 新增 `TestClientErrorResponses` 回归测试类, 覆盖转换期 `ValidationError`、`VLLMValidationError` → 400, `RuntimeError` → 500, 以及 `count_tokens` 路由 → 400, 是本 PR 语义修复的验证主体。
- `tests/entrypoints/serve/exception_handling/test_error_sanitization.py` (模块 错误脱敏; 类别 test; 类型 test-coverage; 符号 `TestAffectedModulesUseSanitize`): rebase 到 #52261 后 `api_router` 改由 `create_error_response` 间接脱敏, 不再直接调用 `sanitize_message`, 因此从源级检查的参数化清单中移除该模块。

关键符号: `create_messages`, `count_tokens`, `translate_error_response`, `TestClientErrorResponses._conversion_error`, `TestClientErrorResponses.test_validation_error_returns_bad_request`, `TestClientErrorResponses.test_generic_error_still_returns_internal_server_error`

关键源码片段

`tests/entrypoints/anthropic/test_anthropic_messages_conversion.py`

新增 `TestClientErrorResponses` 回归测试类, 覆盖转换期 `ValidationError`、`VLLMValidationError` → 400, `RuntimeError` → 500, 以及 `count_tokens` 路由 → 400, 是本 PR 语义修复的验证主体。

```
# tests/entrypoints/anthropic/test_anthropic_messages_conversion.py
# 客户端导致的错误必须是 4xx, 而不是 500 (Issue #52088)
class TestClientErrorResponses:
    @staticmethod
    def _make_api_app(handler: MagicMock):
```

```

app = FastAPI()
attach_router(app)
app.state.args = Namespace(log_error_stack=False)
# 注册 FastAPI 请求校验异常处理器, 保持 schema 校验错误 → 4xx 语义
app.exception_handler(RequestValidationError)(validation_exception_handler)
app.state.anthropic_serving_messages = handler
return app

```

@staticmethod

```

def _request_body() -> dict:
    return {
        "model": "test-model",
        "max_tokens": 1,
        "messages": [{"role": "user", "content": "Hello"}],
    }

```

@staticmethod

```

def _conversion_error() -> ValidationError:
    """构造真实 pydantic ValidationError, 等价于 ChatCompletionRequest
    构造时对 stop 字段超长的校验失败 (复现 Issue #52088 场景) 。"""

```

```

class _StubRequest(BaseModel):
    stop: Annotated[list[str], Field(max_length=4)] | None = None

```

```

with pytest.raises(ValidationError) as exc_info:
    _StubRequest(stop=["a"] * 6)
return exc_info.value

```

```

def test_validation_error_returns_bad_request(self):
    # 转换阶段 pydantic ValidationError 应映射为 400, 而非 500
    handler = MagicMock(spec=AnthropicServingMessages)
    handler.create_messages.side_effect = self._conversion_error()

    app = self._make_api_app(handler)
    with TestClient(app, raise_server_exceptions=False) as client:
        response = client.post("/v1/messages", json=self._request_body())

    assert response.status_code == HTTPStatus.BAD_REQUEST
    body = response.json()
    assert body["type"] == "error"
    assert body["error"]["type"] == "BadRequestError"
    assert "at most 4 items" in body["error"]["message"]

```

```

def test_vllm_client_error_returns_bad_request(self):
    # Serving 层抛出的 VLLMValidationError 也映射为 400
    handler = MagicMock(spec=AnthropicServingMessages)
    handler.create_messages.side_effect = VLLMValidationError(
        "Invalid value for stop", parameter="stop"
    )

```

```

app = self._make_api_app(handler)
with TestClient(app, raise_server_exceptions=False) as client:
    response = client.post("/v1/messages", json=self._request_body())

assert response.status_code == HTTPStatus.BAD_REQUEST
assert response.json()["error"]["type"] == "BadRequestError"

def test_generic_error_still_returns_internal_server_error(self):
    # 非客户端错误必须保持 500，防止服务端故障被误报成客户端问题
    handler = MagicMock(spec=AnthropicServingMessages)
    handler.create_messages.side_effect = RuntimeError("boom")

    app = self._make_api_app(handler)
    with TestClient(app, raise_server_exceptions=False) as client:
        response = client.post("/v1/messages", json=self._request_body())

    assert response.status_code == HTTPStatus.INTERNAL_SERVER_ERROR
    assert response.json()["error"]["type"] == "InternalServerError"

def test_count_tokens_validation_error_returns_bad_request(self):
    # count_tokens 路由同样需要 4xx 语义
    handler = MagicMock(spec=AnthropicServingMessages)
    handler.count_tokens.side_effect = self._conversion_error()

    app = self._make_api_app(handler)
    with TestClient(app, raise_server_exceptions=False) as client:
        response = client.post(
            "/v1/messages/count_tokens", json=self._request_body()
        )

    assert response.status_code == HTTPStatus.BAD_REQUEST
    assert response.json()["error"]["type"] == "BadRequestError"

```

评论区精华

核心讨论围绕『是否手写异常类型判断』展开：DarkLight1337 在本 PR 进行中提醒存在 #52261 异常处理重构，要求跟随 [vllm/entrypoints/serve/utils/server_utils.py](#) 的既有异常处理器逻辑，而不是在 [api_router](#) 里再维护一套类型检查。作者据此把首版手写的 [_translate_exception](#) 分支删除，改为直接调用 [create_error_response\(e\)](#)，让分类语义由共享模块统一保证；[api_router](#) 只负责把结果翻译成 Anthropic 格式。此外，rebase 到 #52261 后出现了两个行为变化需要同步：通用错误映射出的 type 从 [internal_error](#) 变为 OpenAI 风格 [InternalServerError](#)（测试断言随之更新）；[sanitize_message](#) 不再被 [api_router](#) 直接调用（源级检查清单随之移除）。流程上还有多次 merge 冲突提示与 `/ci run`、`/ci retry` 触发，最终由 DarkLight1337 Approve（『Thanks for fixing!』）。

- 复用共享异常处理 [create_error_response](#) 而非手写类型分支 (design): [api_router](#) 统一走 [create_error_response](#) 做异常分类，再经 [translate_error_response](#) 转成 Anthropic 错误格式；净 diff 收敛为 +6/-26。

- rebase 到 #52261 后的错误类型与 sanitize 检查变化 (design): 测试断言更新为 `InternalServerError`; `test_error_sanitization.py` 的参数化清单移除 `api_router`。
- merge 冲突与 CI 触发流程 (other): rebase 到最新 main (含 #52261) 后无冲突合并, CI 通过。

风险与影响

- 风险:
 1. 错误类型字符串变化: rebase 到 #52261 后, 通用异常映射出的错误 type 从原来的 `internal_error` 变为 OpenAI 风格的 `InternalServerError`, 依赖该字符串做监控或客户端分支的用户会观察到差异; 测试已同步更新, 但线上兼容性仍值得留意。
 2. 依赖共享异常映射的语义: `create_error_response` 对异常的分类逻辑集中在 `vllm/entrypoints/serve/exception_handling/error_response.py`, 其中 `pydantic.ValidationError` 因是 `ValueError` 子类被归为客户端错误。若 `serving` 层未来用 `ValueError` 表达服务端故障, 会被误映射为 4xx; 若共享模块调整分类规则, Anthropic 入口会自动继承新行为, 属于「单一职责收益」与「隐式耦合风险」并存。
 3. 流式响应中途错误不在本映射范围: `StreamingResponse` 开始输出后发生的迭代异常发生在 `try/except` 之外, 本次改动未覆盖, 属既有行为, 不是本 PR 引入的回归。
 4. 兼容性: 路由 OpenAPI responses 原本就声明 400/500, 无需文档或客户端适配; 错误消息脱敏仍生效 (间接调用 `sanitize_message`)。- 影响: 用户侧: Anthropic Messages API 与 `count_tokens` 的客户端错误从误导性的 500 变为准确的 4xx, 便于客户端区分输入问题与服务端故障、制定重试策略; 服务端 500 告警的信号价值提升。系统侧: 消除了 `api_router` 中重复的手写错误构造代码, 与 #52261 的整合架构对齐, 后续异常分类改动只需在共享模块进行。团队侧: 新增 `TestClientErrorResponses` 建立了 400/500 边界的回归防线, 并同步维护了 `test_error_sanitization.py` 的源级检查清单, 防止入口脱离统一脱敏路径。影响范围集中在 Anthropic 前端入口层, 不涉及核心调度、注意力或模型代码。- 风险标记: 错误类型字符串变更, 依赖共享异常映射框架语义, 任意 `ValueError` 子类按客户端错误处理, 流式中途错误不受本映射保护 (既有行为)

关联脉络

- PR #51997 [Bugfix][Anthropic] Add max_length on stop_sequences (标题依 PR body 描述推断): PR body 明确提到 #51997 解决了 Issue #52088 的 schema 半部分 (给 `stop_sequences` 增加 `max_length` 约束), 与本 PR 的转换错误映射修复共同闭环同一 issue。
- PR #52261 [Refactor] Consolidate entrypoint exception handling (标题依评审与 commit 描述推断): 评审 DarkLight1337 要求本 PR 对齐该异常处理整合重构; rebase 后复用其 `create_error_response`, 并相应调整测试断言与 `sanitize` 源级检查清单。