

PR #28906 完整报告

sgl-project/sglang

fix(anthropic): detect-and-passthrough mid-conversation system messages

合并时间: 2026-06-26 08:14

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28906>

执行摘要

- 一句话: 自动检测 chat template, 修复 mid-conversation system 消息导致 prefix cache 分叉
- 推荐动作: 该 PR 值得精读。它展示了如何在不增加用户配置开销的前提下, 通过运行时的模板探针来适配不同模型的行为差异, 是解决多模型兼容性问题的良好范例。同时移除了一个与架构不匹配的协议层 validator, 使关注点分离更正确。建议关注 `detect_inline_system_support` 的检测逻辑和 `_convert_to_chat_completion_request` 的转换分支。

功能与动机

PR #26773 无条件将 mid-conversation system 消息提升到顶层, 导致支持内联 system 的 template (如 GLM、Kimi、Qwen3) 的 prefix cache 每轮分叉, TTFT 和吞吐量严重下降 (Issue #28883)。需要根据 template 的实际能力决定是否合并 system 消息, 而不是一刀切。本 PR 采用与 vLLM 一致的方案 (vllm-project/vllm#46025), 通过检测 template 对非首 system 消息的支持能力来动态决策。

实现拆解

1. 新增模板检测函数: 在 `template_detection.py` 中添加 `detect_inline_system_support(chat_template)` 函数。该函数使用 `ImmutableSandboxedEnvironment` 渲染一个 `[system, user, system, user]` 测试对话, 通过检查第二个 system 的 sentinel 文本是否出现在渲染结果中, 来判断 template 是否支持内联 system。如果 template 抛出异常 (如 Qwen 的首 system 守卫) 或 sentinel 被静默丢弃, 则返回 `False` (需要合并)。
2. 服务层集成检测: 在 `serving.py` 的 `AnthropicServing.__init__` 中调用该检测, 并将结果存入 `self._merge_inline_system` 标志。新增 `_chat_template()` 方法从 tokenizer 获取 chat template; 新增 `_extract_system_text()` 辅助函数统一提取 system 内容文本。
3. 转换逻辑调整: 在 `_convert_to_chat_completion_request` 中, 当 `_merge_inline_system` 为 `True` 时, 遍历 `messages` 提取所有 `system` 角色的文本并与顶层 `system` 字段合并为一个 `system` 消息; 同时跳过这些 system 消息避免重复。当为 `False` 时, 保持 system 消息在原位不动。`handle_count_tokens` 复用同一转换路径。
4. 移除协议层 validator: 删除 `protocol.py` 中的 `move_mid_conversation_system_messages` `model_validator`, 因为协议层无法感知 template, 该决策已上移到服务层。

5. 更新测试：重写原有测试用例，分别验证 `merge`（使用 Qwen-style 首 system 守卫模板）和 `passthrough`（使用任意位置 system 模板）两种场景。新增 `TestDetectInlineSystemSupport` 覆盖 `guarded / inline / silent-drop / missing-template` 四种情况。

关键文件：

- `python/sglang/srt/entrypoints/anthropic/serving.py`（模块 服务层；类别 source；类型 core-logic；符号 `_extract_system_text`, `_chat_template`）：核心服务层，新增内联 system 检测、system 文本提取函数，以及根据检测标志决定是否合并 system 消息的逻辑。
- `python/sglang/srt/entrypoints/anthropic/protocol.py`（模块 协议层；类别 source；类型 core-logic；符号 `move_mid_conversation_system_messages`）：移除了无条件提升 mid-conversation system 的 `model_validator`，这是本 PR 的核心清理。
- `python/sglang/srt/managers/template_detection.py`（模块 模板检测；类别 source；类型 dependency-wiring；符号 `detect_inline_system_support`）：新增 `detect_inline_system_support` 函数，是智能决策的核心检测逻辑。
- `test/registered/unit/entrypoints/anthropic/test_serving.py`（模块 测试；类别 test；类型 test-coverage；符号 `init`, `_serving`, `test_in_messages_system_role_folded_to_top_level`, `test_in_messages_system_merged_when_template_requires_first`）：测试覆盖 `merge` 和 `passthrough` 两种场景，新增模板探针测试用例，验证检测函数的正确性。

关键符号：`detect_inline_system_support`, `_extract_system_text`, `_chat_template`, `_convert_to_chat_completion_request`, `init`

关键源码片段

`python/sglang/srt/entrypoints/anthropic/serving.py`

核心服务层，新增内联 system 检测、system 文本提取函数，以及根据检测标志决定是否合并 system 消息的逻辑。

```
# python/sglang/srt/entrypoints/anthropic/serving.py
```

```
def _extract_system_text(
    content: Union[str, list[AnthropicContentBlock]],
) -> Optional[str]:
    """将 system 消息的 content 展平为字符串，返回 None 表示无有效文本。
```

```
    处理 str 和 struct 两种 Anthropic API 允许的格式。"""
```

```
    if isinstance(content, str):
```

```
        return content.strip() or None
```

```
    texts = []
```

```
    for block in content:
```

```
        # 支持 Pydantic model 和 dict 两种形态（HTTP / 编程两种路径）
```

```
        if isinstance(block, BaseModel) and getattr(block, "type", None) == "text":
```

```
            text = getattr(block, "text", "")
```

```
        elif isinstance(block, dict) and block.get("type") == "text":
```

```
            text = block.get("text", "")
```

```

else:
    continue
text = (text or "").strip()
if text:
    texts.append(text)
return "\n".join(texts) if texts else None

```

class AnthropicServing:

```

def __init__(self, openai_serving_chat: OpenAIServingChat):
    self.openai_serving_chat = openai_serving_chat
    # 在初始化时检测 template 能力，一次检测，后续服用
    self._merge_inline_system = not detect_inline_system_support(
        self._chat_template()
    )

def _chat_template(self) -> Optional[str]:
    """从 tokenizer 提取 chat template 字符串。"""
    tokenizer_manager = getattr(self.openai_serving_chat, "tokenizer_manager", None)
    if tokenizer_manager is None:
        return None
    tokenizer = getattr(tokenizer_manager, "tokenizer", None)
    if tokenizer is None:
        return None
    return getattr(tokenizer, "chat_template", None)

```

在 _convert_to_chat_completion_request 中的应用:

```

system_parts: list[str] = []
if anthropic_request.system:
    # 处理顶层 system 字段
    if isinstance(anthropic_request.system, str):
        if anthropic_request.system.strip():
            system_parts.append(anthropic_request.system)
    else:
        for block in anthropic_request.system:
            if block.type == "text" and block.text:
                system_parts.append(block.text)

```

当需要合并时，遍历 messages 提取 system 角色

```

if self._merge_inline_system:
    for msg in anthropic_request.messages:
        if msg.role != "system":
            continue
        text = _extract_system_text(msg.content)
        if text:
            system_parts.append(text)

```

```

if system_parts:
    openai_messages.append(

```

```

        {"role": "system", "content": "\n".join(system_parts)}
    )

```

```

# ... 然后当合并时, 跳过 messages 中的 system 角色消息
for msg in anthropic_request.messages:
    if msg.role == "system" and self._merge_inline_system:
        continue
# ... 其余转换

```

python/sglang/srt/managers/template_detection.py

新增 detect_inline_system_support 函数, 是智能决策的核心检测逻辑。

```

# python/sglang/srt/managers/template_detection.py

```

```

def detect_inline_system_support(chat_template: Optional[str]) -> bool:
    """检测 chat template 是否支持内联 system 消息。

```

返回 True 表示模板可以将 system 消息渲染在任何位置 (passthrough) ;
 返回 False 表示必须合并到首位 system 块 (merge) 。
 检测方法: 渲染一个 [system, user, system, user] 探针,
 如果第二个 system 的 sentinel 文本出现在输出中, 说明模板处理了非首 system。
 如果模板抛出异常或静默丢弃第二个 system, 返回 False。"""

```

if not chat_template:
    return False # 无模板时保守默认: 合并
sentinel = "__sglang_inline_system_sentinel__"
try:
    # 使用 sandbox 环境避免模板注入风险
    env = jinja2.sandbox.ImmutableSandboxedEnvironment(
        trim_blocks=True,
        lstrip_blocks=True,
        extensions=[jinja2.ext.loopcontrols],
    )
    rendered = env.from_string(chat_template).render(
        messages=[
            {"role": "system", "content": "t"},
            {"role": "user", "content": "t"},
            {"role": "system", "content": sentinel},
            {"role": "user", "content": "t"},
        ],
        add_generation_prompt=False,
    )
    return sentinel in rendered
except jinja2.TemplateError:
    return False # 模板抛出异常 (如 Qwen 的 loop.first 守卫) → 合并
except Exception:
    return False # 任何其他异常 → 保守合并

```

评论区精华

review 中 [gemini-code-assist\[bot\]](#) 提出使用 tokenizer 的 `apply_chat_template` 方法进行检测，因为 tokenizer 已经注册了正确的自定义过滤器和全局变量（如 `raise_exception`），可以避免手动 Jinja 环境可能导致的假阳性。但最终实现未采纳该建议，仍使用 `ImmutableSandboxedEnvironment`，原因可能是保持检测过程轻量 and 独立。此外，该 bot 还建议注册一个 dummy `raise_exception` 来更好处理保险箱模板，但最终代码通过捕获 `jinja2.TemplateError` 来处理，也足够。这些建议未在最终代码中体现，但 PR 已被批准合并。

- 使用 `tokenizer.apply_chat_template` 替代手动 Jinja 渲染 (design): PR 作者未采纳该建议，最终代码仍使用 `ImmutableSandboxedEnvironment` 手动渲染。但通过捕获 `TemplateError` 也达到了类似效果。PR 被批准合并，说明 reviewer 认为当前方案足够。

风险与影响

- 风险：
 - 模板检测误判风险：`detect_inline_system_support` 使用手动 Jinja 环境，可能缺失某些自定义全局变量或过滤器，导致模板渲染异常被当成不支持内联（返回 `False`）而合并 `system` 消息；相反，如果模板返回不符合预期但 `sentinel` 巧合出现，可能返回 `True` 导致 `system` 消息被放置在不适用的位置。当前通过 `sentinel` 检测和异常捕获，风险较低但存在边缘情况。
 - API 兼容性回归：对于原本需要合并的模板（如 Qwen），本 PR 的行为应与之前一致；但对于支持内联的模板，其行为从合并变为保留原位，可能打破依赖之前行为（如期望 `system` 消息总在首位）的客户端。不过这更符合 Anthropic API 规范。
 - prefix cache 性能改善：对于支持内联的模板，性能显著提升；但若误判为不支持，则性能下降（回到合并状态）。
 - 代码维护风险：检测逻辑嵌入在 `AnthropicServing` 中，如果 tokenizer 的 `chat template` 在运行时动态变化（少见），会导致不一致。
- 影响：
 - 用户影响：Claude Code 用户的多轮 agent 场景下，`mid-conversation steer` 消息能够正确生效，且 `prefix cache` 保持稳定，显著降低 TTFT 和提升吞吐量。对于只使用单轮或不支持内联模板的用户无影响。
 - 系统影响：增加了初始化时的模板渲染开销（一次），但检测结果可缓存。转换路径增加分支，但开销可忽略。
 - 团队影响：新增了一个可复用的模板检测函数，未来可用于其他需要判断模板能力的地方。代码结构更清晰（协议层不再负责语义决策）。
 - 影响程度：中等到高，因为修复了一个真实性能回归，且未引入新的配置项，自动适配。
 - 风险标记：Anthropic API 核心路径，模板检测误判风险，API 兼容性回归，初始化开销

关联脉络

- PR #26773 [fix] Add mid-conversation system message support for Anthropic API: 本 PR 的前置修复，首次添加了 `system` 角色支持但使用了无条件合并方案，导致了本 PR 解决的回归问题。

- PR #28883 [Anthropic] Mid-conversation system messages are hoisted to top-level, forking the prefix cache on inline-capable templates: 本 PR 修复的 Issue, 详细描述了问题影响和期望行为。