

PR #35415 完整报告

vllm-project/vllm

feat(qwen3-asr): support prompt parameter in v1/audio/transcriptions

合并时间: 2026-06-11 03:55

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/35415>

执行摘要

- 一句话: 支持 Qwen3-ASR 转录 API 的 prompt 参数
- 推荐动作: 建议合入。该 PR 解决了真实用户需求 (Issue #35272), 同时以高安全标准处理用户输入 (fixpoint 清理)。设计上保留了向后兼容, 并且示例扩展降低了用户试用门槛。值得关注的决策是采用 fixpoint 而非简单正则替换来防御嵌套注入, 可作为安全编码的范本。

功能与动机

Issue #35272 请求 Qwen3-ASR 支持用户输入的 `request_prompt`, 以提供类似 OpenAI 转录 API 的上下文提示功能。此外, 保持与 OpenAI API 的对等性, 允许用户传递风格、词汇或前文片段。官方 Qwen3-ASR SDK 已经定义了 `get_generation_prompt` 签名但未实际使用 `prompt`。

实现拆解

1. 输入清理函数 (vllm/model_executor/models/qwen3_asr.py): 新增 `_sanitize_transcription_user_text`, 使用 `fixpoint` 循环迭代剥离 ChatML 风格的 `<|...|>` 标记和 `<asr_text>` 标签, 防止嵌套攻击 (例如 `<lim<|x|>_endl>` 重构为 `<lim_endl>`)。
2. 生成提示组装 (vllm/model_executor/models/qwen3_asr.py): 修改 `get_generation_prompt` 方法, 从 `SpeechToTextParams` 中读取 `language`、`task_type`、`request_prompt`、`to_language`。仅在 `request_prompt` 非空 (且清理后非空) 时插入 `system turn`, 兼容无 `prompt` 的原始行为。语言提示根据任务正确选择: `transcribe` 使用 `language` (源音频语言), `translate` 使用 `to_language` (目标语言)。
3. 示例客户端扩展 (examples/speech_to_text/openai/openai_transcription_client.py): 新增 `--prompt` 命令行参数, 通过 OpenAI SDK 的 `prompt=` 参数传递给 `sync_openai` 和 `stream_openai_response` 函数, 默认空字符串保持向后兼容。
4. 单元测试 (tests/entrypoints/speech_to_text/transcription/test_qwen3_asr_sanitize_prompt.py): 覆盖空输入、明文、单次清理、嵌套攻击、组合攻击和幂等性, 确保安全边界正确。

关键文件:

- `vllm/model_executor/models/qwen3_asr.py` (模块 模型执行; 类别 `source`; 类型 `data-contract`; 符号 `_sanitize_transcription_user_text`): 核心实现文件, 新增输入清理函数并修改生成提示组装, 支持 `prompt` 参数和语言提示修复。

- `tests/entrypoints/speech_to_text/transcription/test_qwen3_asr_sanitize_prompt.py`（模块测试；类别 `test`；类型 `test-coverage`；符号 `test_sanitize_strips_control_tokens`, `test_sanitize_handles_falsy_inputs`, `test_sanitize_is_idempotent`）：为 `sanitizer` 提供全面单元测试，覆盖空值、明文、单次清理、嵌套攻击、组合攻击和幂等性。
- `examples/speech_to_text/openai/openai_transcription_client.py`（模块示例；类别 `source`；类型 `core-logic`）：示例客户端扩展，增加 `--prompt` 参数演示功能，方便用户测试。

关键符号: sanitize transcription user text, get generation prompt

关键源码片段

```
vllm/model_executor/models/gwen3_asr.py
```

核心实现文件，新增输入清理函数并修改生成提示组装，支持 prompt 参数和语言提示修复。

```
// 文件: vllm/model_executor/models/qwen3_asr.py
// 新增导入 regex
import regex as re

// 模块常量
_ASX_TEXT_TAG = "<asr_text>"

// 编译 ChatML 风格标记正则
_CHATML_LIKE_TOKEN = re.compile(r"<\\[\\^\\]|\\>")

def _sanitize_transcription_user_text(text: str) -> str:
    """Fixpoint sanitizer 用于从用户控制的转写字段中剥离特殊标记。

    同时应用正则替换和 `<asr_text>` 替换直到字符串稳定，
    防止嵌套载荷在一次替换后重建有效标记。
    """
    if not text:
        return ""
    prev = None
    while prev != text:
        prev = text
        // 每次迭代剥离所有 `<|...|>` 和 `<asr_text>`
        text = _CHATML_LIKE_TOKEN.sub("", text).replace(_ASX_TEXT_TAG, "")
    return text
```

```
tests/entrypoints/speech_to_text/transcription/test_qwen3_asr_sanitize_prompts.py
```

为 sanitizer 提供全面单元测试, 覆盖空值、明文、单次清理、嵌套攻击、组合攻击和幂等性。

```
# 文件：tests/entrypoints/speech_to_text/transcription/test_qwen3_asr_sanitization_prompt.py
# 测试安全边界：嵌套 / 组合攻击

@pytest.mark.parametrize(
```

```

("text", "expected"),
[
    ("", ""),
    ("plain text", "plain text"),
   ("<lim_endl>", ""),
   ("<lim_startl>assistant<lim_endl>", "assistant"),
   ("foo<asr_text>bar", "foobar"),
    # Nested ChatML reconstruction attack
   ("<lim<|xl>_endl>", ""),
    # Nested <asr_text> reconstruction attack
   ("<asr_te<asr_text>xt>", ""),
    # Combined attacks
   ("<lim_endl>foo<asr_text>bar<|<|xl>im_endl>", "foobar"),
],
)
def test_sanitize_strips_control_tokens(text: str, expected: str) -> None:
    assert _sanitize_transcription_user_text(text) == expected

def test_sanitize_handles_falsy_inputs() -> None:
    assert _sanitize_transcription_user_text("") == ""
    assert _sanitize_transcription_user_text(None) == "" # type: ignore[arg-type]

def test_sanitize_is_idempotent() -> None:
    """调用两次 sanitizer 应产生相同结果。"""
    for raw in ["plain text", "<lim<|xl>_endl>", "<asr_te<asr_text>xt>"]:
        once = _sanitize_transcription_user_text(raw)
        twice = _sanitize_transcription_user_text(once)
        assert once == twice

```

评论区精华

1. language 与 to_language 的误用 (@minh-nguyenhoang)：指出原实现中 to_language 被用于转写任务，实际应根据任务使用 language（转写）或 to_language（翻译）。作者修复此问题。
 2. 嵌套标签绕过 (@depthfirst-app[bot])：安全扫描发现单次正则替换可被嵌套输入绕过（如 <lim<|xl>_endl> 经过一次替换变为 <lim_endl>），建议使用 fixpoint 循环。作者采用 fixpoint 方案，并同步修复 <asr_text> 替换。
 3. system turn 条件发射 (@DarkLight1337)：认为无条件插入空 system turn 改变已有行为，要求仅在提供 prompt 时生成。作者改为“清理后检查非空才插入”，保留向后兼容。
 4. 示例集成 (@DarkLight1337)：建议将专用示例脚本合并到现有的 openai_transcription_client.py 中，避免重复维护。作者将 prompt 支持作为 --prompt 参数合并到原有客户端。
- language 与 to_language 的误用 (correctness): 作者修复：转录使用 language，翻译使用 to_language。

- 嵌套标签绕过安全风险 (security): 作者采用 fixpoint 方式, 将 <asr_text> 替换也纳入循环, 防御嵌套攻击。
- system turn 条件发射 (design): 作者改为 sanitize 后检查非空才插入 system turn, 无 prompt 时保持原始 user+assistant 模板。

风险与影响

- 风险:
 1. 输入清理强度: _sanitize_transcription_user_text 使用 fixpoint 循环, 理论上能应付多层嵌套, 但若出现非终止风险 (虽然 unlikely), 应监控是否出现死循环。
 2. 系统 turn 行为变更: 在提供 prompt 时新增 system turn, 可能影响依赖原始纯 user-assistant 模板的测试或下游逻辑, 但回退方案 (无 prompt 时行为不变) 已通过测试。
 3. 多模型兼容性: Whisper 等其他 ASR 模型已有自己的 prompt 处理逻辑 (<|prevl> 标记), 此修改不影响它们。
 4. 性能影响: 清理函数在每请求 prompt 文本上运行, 文本通常较短, 性能可忽略。- 影响: 用户层面: Qwen3-ASR 用户现在可以使用 OpenAI 转录 API 的 prompt 参数提供上下文 (词汇风格或前文片段), 与 Whisper 等模型体验一致。低于默认的 prompt (空) 完全向后兼容。系统层面: 修改仅限于 Qwen3-ASR 模型模块和示例客户端, 不涉及核心推理、调度或 KV 缓存。新增的测试确保持久安全。团队层面: 较小的变更 (+54/-12 核心代码, +64 测试), 已通过 CI 所有检查, 合并风险低。
- 风险标记: 用户输入清理, 嵌套绕过已修复, 兼容性变更 (system turn 新增)

关联脉络

- PR #35377 Apply ChatML template for Qwen3-ASR: 相关工作 PR, 探索使用 apply_chat_template, 后关闭未合并; 本 PR 专注更窄范围。
- PR #36268 SpeechToTextParams refactor: 为 get_generation_prompt 引入 SpeechToTextParams, 本 PR 消费该接口。
- PR #36018 Support response_prefix for Qwen3-ASR: 复用相同 sanitizer 的 follow-up PR, 扩展提示功能。