

# PR #51391 完整报告

vllm-project/vllm

[Bugfix][Parser] Prevent Inkling block-end leakage with tools

合并时间: 2026-08-09 00:34

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/51391>

## 执行摘要

- 一句话: 修复 Inkling 工具启用时块结束 token 泄漏进 content
- 推荐动作: 值得精读。核心设计决策是: 语义事件 (TOOL\_CALL\_START / TOOL\_CALL\_END) 不能作为词法工具区域的边界依据, 应改由状态转移结构推导; 同时 transition is None 分支也要同步清理转发状态。这对任何使用共享 parser engine 新增 grammar 的开发者都有直接借鉴意义, 也建议后续为嵌套 / 多 wrapper 工具区域补充更细粒度的测试。

## 功能与动机

issue #51387 报告: 启用 `--enable-auto-tool-choice --tool-call-parser inkling --reasoning-parser inkling` 后, 模型在 tool result 之后用纯文本回答 (无 thinking 块、无 tool call) 时, 响应 content 以字面量 `<lend_message>` 结尾, agent 框架在每一轮工具调用后的 synthesis 回合都会命中。issue 定位到两处互配根因: 一是 `StreamingParserEngine.on_terminal` 的 `skip_tool_parsing` 分支刻意把块结束终端透传为 content 供下游 tool pass 消费, 但无工具块时 tool pass 不启动, 标记直达客户端; 二是 `DelegatingParser.extract_tool_calls` 无工具调用分支返回 pre-tool-pass content, 丢弃了 tool parser 已消费掉标记的版本。PR body 还明确本 PR 不重复 #49876 (no-tools 纯文本模式) 和 #50528 (无 thinking 块时的 tool-call 交接)。

## 实现拆解

1. 变更入口: `vllm/parser/engine/streaming_parser_engine.py` 的 `StreamingParserEngine` 是 reasoning/tool 双 pass 共用的底层引擎; `skip_tool_parsing=True` 时由 reasoning pass 转发工具语法、tool pass 在下一阶段消费, 泄漏发生在这条转发路径上。
2. 新增结构推导出口集合: 在 `__init__` 中新增 `_tool_exit_terminals`, 从 `config.transitions` 提取所有“工具状态 → 非工具状态”转移对应的 terminal。相比用 `TOOL_CALL_END` 事件识别, 结构推导能覆盖 `MiniMax` 这类语义事件与词法 wrapper 不一致的 grammar。
3. 新增转发 span 状态: `_in_skipped_tool_span` 表示 reasoning pass 当前是否处于需要逐字转发的词法工具区域; reset 时清零, 保证 parser 跨请求复用不串扰。
4. 改造 `_on_terminal` 分支: 对共享块结束 token, 用 `is_opener / is_exit / used_as_plain_closer` 三段判断——工具区域之外作为普通文本 / 推理结束标记走正常 transition 被消费; 区域之内打开 span、完整转发工具语法; 对 `transition is None` 的

wrapper closer 也显式清除 span，避免 stale 状态使后续文本 closer 误走转发路径。

5. 测试与验证配套：tests/parser/engine/test\_inkling.py 新增 TestDelegatingTwoPass（served 双 pass 路径，覆盖 streaming/non-streaming、纯文本、推理后文本、多工具往返、parser 复用、两种结束 token、无转移 closer）；tests/parser/engine/test\_parser\_engine.py 新增 TestSkipToolSpanForwarding（共享引擎层验证 span 转发与清理）。bbrowning 另行跑了 parser engine 全量单测与多个模型的 reasoning/tool parser 测试，共 4064 passed。

关键文件：

- vllm/parser/engine/streaming\_parser\_engine.py（模块 解析引擎；类别 source；类型 core-logic；符号 StreamingParserEngine.init, StreamingParserEngine.reset, StreamingParserEngine.\_on\_terminal）：共享 parser engine 核心逻辑：新增 \_tool\_exit\_terminals 结构推导、\_in\_skipped\_tool\_span 状态与 \_on\_terminal 分支改造，是本次修复的主体。
- tests/parser/engine/test\_inkling.py（模块 解析器；类别 test；类型 test-coverage；符号 \_function\_tool, \_delegating, \_stream\_delegating, TestDelegatingTwoPass）：新增 TestDelegatingTwoPass 提供 served 双 pass 路径的回归覆盖，直接复现 issue 的 streaming/non-streaming 泄漏场景。
- tests/parser/engine/test\_parser\_engine.py（模块 引擎测试；类别 test；类型 test-coverage；符号 TestSkipToolSpanForwarding, \_skip\_engine, test\_tool\_syntax\_forwarded\_and\_span\_cleared, test\_span\_not\_stale\_across\_two\_tool\_calls）：新增 TestSkipToolSpanForwarding 在共享引擎层验证 span 转发、跨两次工具调用不 stale、以及 transitionless closer 后的内容消费契约。

关键符号：StreamingParserEngine.init, StreamingParserEngine.reset, StreamingParserEngine.\_on\_terminal, TestDelegatingTwoPass.test\_plain\_text\_non\_streaming, TestSkipToolSpanForwarding.test\_content\_after\_transitionless\_closer\_observable

## 关键源码片段

### vllm/parser/engine/streaming\_parser\_engine.py

共享 parser engine 核心逻辑：新增 `_tool_exit_terminals` 结构推导、`_in_skipped_tool_span` 状态与 `_on_terminal` 分支改造，是本次修复的主体。

```
# 在 __init__ 中基于状态转移结构推导词法工具区域的出口集合。
# 不用 TOOL_CALL_END 语义事件的原因是：MiniMax 的 </invoke> 会触发
# TOOL_CALL_END，但外层 <minimax:tool_call> wrapper 的关闭没有任何事件；
# 因此统一用“工具状态 -> 非工具状态”的转移来识别出口。
self._tool_exit_terminals: frozenset[str] = frozenset(
    terminal
    for (state, terminal), tr in config.transitions.items()
    if state in self._TOOL_STATES and tr.next_state not in self._TOOL_STATES
)

# reset 时清除上一请求遗留的转发 span，避免 parser 复用时状态串扰。
```

```
self._in_skipped_tool_span = False
```

```
def _on_terminal(self, terminal: str, value: str) -> list[SemanticEvent]:
```

```
    key = (self.state, terminal)
```

```
    transition = self.config.transitions.get(key)
```

```
    if transition is None:
```

```
        # skip pass 投影后的状态可能没有该 terminal 的转移
```

```
        # （Qwen3 / DeepSeek / GLM 4.7 MoE / Nemotron v3 的 wrapper closer
```

```
        # 都只在工具状态定义）。此时依然要清除 span，否则它会在请求
```

```
        # 剩余阶段保持 True，后续普通文本 closer 会被误转发并泄漏。
```

```
        if self.skip_tool_parsing and terminal in self._tool_exit_terminals:
```

```
            self._in_skipped_tool_span = False
```

```
        return self._emit_for_state(value)
```

```
    if self.skip_tool_parsing and terminal in self._tool_terminals:
```

```
        # Inkleing 复用同一个块结束 token 作为工具、文本、推理三种出口，
```

```
        # 因此不能只按 terminal 身份分类。规则是：词法工具区域之外按正常
```

```
        # 转移消费 closer；区域之内则完整转发工具语法（含 wrapper closers）。
```

```
        is_opener = transition.next_state in self._TOOL_STATES
```

```
        is_exit = terminal in self._tool_exit_terminals
```

```
        used_as_plain_closer = (
```

```
            is_exit and not is_opener and not self._in_skipped_tool_span
```

```
        )
```

```
    if not used_as_plain_closer:
```

```
        if is_opener:
```

```
            self._in_skipped_tool_span = True
```

```
        elif is_exit:
```

```
            self._in_skipped_tool_span = False
```

```
    if self.state == ParserState.MESSAGE_HEADER:
```

```
        self.state = ParserState.CONTENT
```

```
        self._message_header_buffer = ""
```

```
        return [
```

```
            SemanticEvent(
```

```
                EventType.TEXT_CHUNK,
```

```
                value=value,
```

```
                tool_index=self.tool_index,
```

```
            )
```

```
        ]
```

```
    if EventType.REASONING_END in transition.events:
```

```
        self.state = ParserState.CONTENT
```

```
        return [
```

```
            SemanticEvent(
```

```
                EventType.REASONING_END,
```

```
                value=value,
```

```
                tool_index=self.tool_index,
```

```
            ),
```

```
            SemanticEvent(
```

```

        EventType.TEXT_CHUNK,
        value=value,
        tool_index=self.tool_index,
    ),
]
content_type = self.config.content_events.get(self.state)
if content_type is not None:
    return [
        SemanticEvent(
            content_type,
            value=value,
            tool_index=self.tool_index,
        )
    ]
return []
# used_as_plain_closer 为 True: 这是纯文本 / 推理的结束标记,
# 落到下方原有路径, 按正常转移消费, 不再透传给调用方。
# 原有: 普通转移、skip_in_token_id_mode 与 _apply_transition 处理保持不变。

```

## 评论区精华

- 词法区域 vs 语义事件 (bbrowning, CHANGES\_REQUESTED) : TOOL\_CALL\_START / TOOL\_CALL\_END 描述的是语义调用, 不一定是 skip pass 必须保留的词法 wrapper。MiniMax 是典型案例: <minimax:tool\_call> 打开词法区域时没有 TOOL\_CALL\_START, </minimax:tool\_call> 关闭时也没有 TOOL\_CALL\_END, 因此建议边界改为结构转移推导。
- transitionless closer 的 stale 状态 (bbrowning) : Qwen3、DeepSeek v3.2/v4、GLM 4.7 MoE、Nemotron v3 的 wrapper closer 只在工具状态定义, skip pass 位于 CONTENT 时 transition is None 提前返回, 会让 passthrough 标志在请求剩余阶段保持 True, 普通输出测试可能漏掉。
- 独立验证 (bbrowning, APPROVED) : 跑了 parser engine 全量单测 + deepseek/gemma4/glm4\_moe/minimax\_m2/qwen3 等模型的 reasoning/tool parser 测试, 4064 passed; live server 复现脚本从 2 pass/4 fail/2 inconclusive 提升到 5 pass/1 fail/2 inconclusive, 剩余失败与 #49876、#50528 相关, 由作者们协调落地。
- 词法工具区域边界应以结构转移而非语义事件定义 (design): 最终实现采纳结构性边界, 新增 `_tool_exit_terminals` 推导与 `_in_skipped_tool_span` 跟踪。
- transitionless wrapper closer 会导致 span 状态 stale (correctness): 在 transition is None 分支补上 `_tool_exit_terminals` 检查并清除 span, 新增对应回归测试。
- 回归验证范围 (testing): 已批准; 剩余失败与 #49876、#50528 相关, 由作者们协调后续落地。

## 风险与影响

- 风险: streaming\_parser\_engine.py 是共享引擎, qwen3/deepseek/glm47\_moe/nemotron\_v3 等所有 engine-backed parser 都经过该路径, 本次改动虽经 4064 个单测回归, 但 live 环境仍存在 1 个失败用例 (与

#49876/#50528 相关)，说明 Inkling 整体解析尚不稳定。\_in\_skipped\_tool\_span 是新增可变状态，任何提前 return 路径若未正确清理，都可能造成同类泄漏或反向误消费；当前测试覆盖主要场景，但嵌套工具区域等边缘未穷尽。本 PR 未运行实时模型评估，仅 CPU-only 确定性测试，后续接入真实 Inkling 权重时建议再做一次端到端回归。

- 影响：用户侧：启用 Inkling tool-calling 的请求（尤其是 agent 循环中 tool result 之后的 synthesis 回合）不再收到尾部脏标记，流式与非流式同时修复，content 与 reasoning 的划分更符合 OpenAI 兼容协议预期。系统侧：共享 parser engine 的行为变化影响所有 engine-backed parser，但工具区域内转发、区域外消费的语义被保留，回归面集中在新的 span 状态清理逻辑；对推理性能和 GPU 路径无影响。团队侧：与 #49876、#50528 构成 Inkling 解析修复序列，三个 PR 互补，需要协同合入并统一做一次带真实模型的端到端验证。
- 风险标记：共享引擎核心路径变更，无实时模型验证，新增状态变量需跨请求清理

## 关联脉络

- PR #49876 [Bugfix][Parser] Confirm reasoning end when an Inkling content block opens: 同一 Inkling 解析问题线；PR body 明确说明本 PR 不重复 #49876（no-tools 纯文本模式），二者需要协同合入。