

PR #34237 完整报告

sgl-project/sglang

[Fix] lfm2 detector: recover tool calls dropped by common model-output...

合并时间: 2026-08-23 18:09

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34237>

执行摘要

- 一句话: 修复 LFM2 检测器丢弃合法工具调用的问题
- 推荐动作: 值得精读。核心看点: 1) 恢复阶梯的设计哲学——所有重写都是确定性的、保值的, 并以 `ast.parse` 成功为唯一接受标准, “无法唯一判定就拒绝”的 fail-closed 原则避免了猜测性修复引入更坏的静默数据损坏; 2) “调用数不变量”防止晚闭合引号把兄弟调用吞进参数值, 是本次最有洞察力的防护; 3) 19 个回归用例逐一验证修复前必失败, 加上与 vLLM 的 42-payload 差分对齐, 测试方法本身很有参考价值。只关心功能的读者可直接看 PR body 的三张 Before/After 表格, 它本身就是一份优秀的 bug 分类清单。

功能与动机

PR body 明确说明动机来自真实负载: “Running real LFM2/LFM2.5 agent traces (SWE-agent / shell-command workloads) through Lfm2Detector turned up three distinct kinds of problem.” 三类问题按“是否解析器的错”分层:

1) 合法 Python 被误拒 (limit=+7 只有 USub 分支、set 字面量、无占位符 f-string 都导致调用被丢弃); 2) 发出错误数据——1e999 序列化成 Infinity 非法 JSON、位置参数 'Paris' 静默丢失、**kwargs 静默缺失、bytes 参数连坐整块调用、单个坏引号让整块 SyntaxError, “比不报告更糟, 工具会在错误输入上执行”; 3) 模型确实写了非法 Python (裸换行、NUL 字节、前导零整数、嵌套引号) 时解析器直接放弃。作者同时说明这是 vLLM 同格式修复的移植: “These mirror the fixes recently merged for the same tool-call format in vLLM (vllm-project/vllm#48171); this port is adapted to Lfm2Detector's structure (per-call salvage, buffered streaming) and touches no other detector.”

实现拆解

1. 变更入口与恢复阶梯: `python/sglang/srt/function_call/lfm2_detector.py` 的 `_parse_pythonic_content` 在 `safe_ast_parse` 失败后进入恢复循环, 依次尝试 `_recovery_candidates` 组织的一组模块级纯函数重写, 每个候选重新解析、任一成功即采用。这些 helper 包括: `_escape_ctrl_chars_in_strings` (把字符串内的裸换行 / 回车 / 制表符 / NUL 转义为 `\n\r\t\x00`, 同时规避 SyntaxError 与 ValueError 且保值)、`_normalize_leading_zero_ints` (剥离十进制整数字面量前导零, 放过 `0x/` 浮点 / 指数 / 全零等合法形态)、`_rename_reserved_kwargs/_restore_reserved_kwarg_names` (仅在关键字参数位置把 `from=1` 改成 `from_pyreservedkw=1`, 解析后精确还原, 且不误伤 `==` 比较)、`_escape_nested_quotes_in_strings` (对 broken 字符串枚举所有候选闭合引号、转

义内部同风格引号并逐个 `ast.parse` 校验，恰好一个候选才恢复）。

2. 参数提取与单调用语义加固：`_get_parameter_value` 新增 `UAdd`（显式正号，且拒绝 `-True`）、`Set`（按源码顺序转 `list`）、全 `Constant` 的 `JoinedStr`（无占位符 `f-string` 折叠为字符串），并把 `Constant` 限定为 `None/str/int/float`，让 `bytes/Ellipsis/` 复数在提取期就被拒绝。`_parse_pythonic_call` 改用 `json.dumps(..., allow_nan=False)`，序列化失败只跳过当前调用；`**` 解包的字面量 `dict` 按 `later-binding-wins` 合并，非 `dict` 操作数拒绝调用；含位置参数的调用直接拒绝，不再静默丢失位置参数值后照常交付。
3. 块级抢救与流式继承：当整块候选全部无法解析时，用 `_split_top_level_calls` 按顶层逗号把块切成独立段，每段单独走同一恢复阶梯，保证 `[read(path='/x'), bash(command='grep 'e' a.log')]` 里合法的 `read` 存活；切分同时跑字符串感知与纯括号计数两遍扫描，避免坏引号隐藏分隔符。流式路径 `parse_streaming_increment` 缓冲完整块后委托给 `detect_and_parse`，自动继承全部恢复逻辑，无需单独实现。
4. PythonicDetector 兄弟修复：`python/sglang/srt/function_call/pythonic_detector.py` 移植其中两个可观测缺陷——按调用粒度捕获 `ValueError/TypeError`（不再连坐整块），并 `allow_nan=False` 序列化；其正则门槛本来就拒绝位置参数与 `**` 解包，故这两个类无需移植。
5. 测试配套：`test/registered/unit/function_call/test_function_call_parser.py` 新增 19 个回归用例（17 个在 `TestLfm2Detector`，其余覆盖 `PythonicDetector` 的同类缺陷），每个都验证了“修复前必失败”，覆盖恢复正确分支与歧义拒绝的负向分支（如 `test_ambiguous_nested_quotes_not_guessed`、`test_swallowing_reading_rejected`）。另用 42 个 payload（vLLM 测试常量、对抗性引号 / 转义用例、真实 SWE-agent 轨迹）做差分测试，确认与 vLLM 合并版解析器输出完全一致。

关键文件：

- `python/sglang/srt/function_call/lfm2_detector.py`（模块 调用检测；类别 `source`；类型 `core-logic`；符号 `_rename_reserved_kwargs`, `_restore_reserved_kwarg_names`, `_is_escaped`, `_escape_nested_quotes_in_strings`）：本 PR 的核心修复文件：新增 4 组模块级恢复重写 `helper`、恢复阶梯 `_recovery_candidates` 与 `_parse_pythonic_content` 中的重试循环，并强化 `_get_parameter_value` 与 `_parse_pythonic_call`。所有恢复逻辑只在 `ast.parse` 失败后触发，正常路径零开销。
- `test/registered/unit/function_call/test_function_call_parser.py`（模块 解析测试；类别 `test`；类型 `test-coverage`；符号 `test_non_finite_argument_never_emits_invalid_json`, `test_unconvertible_argument_skips_only_that_call`, `test_multiline_string_argument_recovered`, `test_nul_byte_in_string_argument_recovered`）：19 个回归用例全部覆盖“修复前必失败”的场景，其中 `test_swallowing_reading_rejected` 锁定了“晚闭合读法吞掉兄弟调用”这一最关键不变量，`test_ambiguous_nested_quotes_not_guessed` 锁定歧义拒绝的负向分支；PR body 声明这些用例都先在旧实现上验证失败。
- `python/sglang/srt/function_call/pythonic_detector.py`（模块 调用检测；类别 `source`；类型 `core-logic`；符号 `detect_and_parse`, `_get_parameter_value`）：移植 LFM2 修复中在 `PythonicDetector` 可观测的两个缺陷：非有限浮点序列化为 `Infinity`、不可转换参数连坐整块调用；改为按调用粒度捕获并跳过，`_get_parameter_value` 同时限定 `Constant` 为

JSON 可表示类型。

关键符号: `_rename_reserved_kwargs`, `_restore_reserved_kwarg_names`, `_is_escaped`, `_escape_nested_quotes_in_strings`, `_escape_ctrl_chars_in_strings`, `_normalize_leading_zero_ints`, `_recovery_candidates`, `_split_top_level_calls`, `_parse_pythonic_call`, `_parse_pythonic_content`, `_get_parameter_value`

关键源码片段

python/sclang/srt/function_call/lfm2_detector.py

本 PR 的核心修复文件: 新增 4 组模块级恢复重写 helper、恢复阶梯 `_recovery_candidates` 与 `_parse_pythonic_content` 中的重试循环, 并强化 `_get_parameter_value` 与 `_parse_pythonic_call`。所有恢复逻辑只在 `ast.parse` 失败后触发, 正常路径零开销。

```
def _escape_nested_quotes_in_strings(text: str) -> Tuple[str, bool]:
    """恢复被嵌套引号破坏的字符串参数（仅在歧义唯一时）。
```

模型输出的 shell 命令常把同风格引号嵌套进字符串参数, 例如
`command='sed -n '360,450p' f.py'`, Python 会把 `sed -n ` 与
数字 `360` 视作并列表达式 (juxtaposition) 报 `SyntaxError`, 导致
整块调用被丢弃。这里把“第一个未转义引号无法在语法上闭合该字符串”
视为 broken, 再枚举每个语法上可行的闭合引号, 转义中间的同风格
引号并做 `ast.parse` 校验; 恰好一个候选可解析才恢复, 零个或多个
候选视为真正歧义, 原样返回、绝不猜测。

```
"""
```

```
def unescaped_quotes(start: int, quote: str) -> List[int]:
    # 收集从 start 起的未转义同风格引号位置, 遇到反斜杠成对跳过
    positions = []
    j = start
    while j < len(text):
        if text[j] == "\\":
            j += 2
            continue
        if text[j] == quote:
            positions.append(j)
        j += 1
    return positions
```

```
def is_closer(pos: int) -> bool:
    # 引号后（允许空白）紧跟 ,)}}: 之一才是语法上可行的闭合点;
    # 否则说明字符串在中间被打断, 处于 broken 状态
    k = pos + 1
    while k < len(text) and text[k].isspace():
        k += 1
    return k < len(text) and text[k] in _QUOTE_FOLLOWERS
```

关键不变量: 晚闭合的候选可能把兄弟调用吞进字符串值里, 例如
`f(a='x 'y'), g(...)` 会被读成单个调用、`g(...)` 被塞进 `a`,

```

# 工具将拿到被污染的参数执行——比丢弃更糟。括号计数不受坏引号
# 影响，因此用顶层调用数作为候选的合法性门槛。
expected_calls = len(_split_top_level_calls(text, respect_strings=False))
prefix: List[str] = []
index = 0
while index < len(text):
    char = text[index]
    if char not in {"'", '"'}:
        prefix.append(char)
        index += 1
        continue
    quotes = unescaped_quotes(index + 1, char)
    if not quotes:
        return text, False
    if is_closer(quotes[0]):
        # 第一个引号就能正常闭合，按原样消费这一段
        prefix.append(text[index : quotes[0] + 1])
        index = quotes[0] + 1
        continue
    winners = []
    for close in (j for j in quotes if is_closer(j)):
        interior: List[str] = []
        for j in range(index + 1, close):
            if text[j] == char and not _is_escaped(text, j):
                interior.append("\\")
            interior.append(text[j])
        candidate = "".join(
            ["".join(prefix), char, "".join(interior), char, text[close + 1 :]]
        )
        try:
            module = safe_ast_parse(_escape_ctrl_chars_in_strings(candidate))
        except (SyntaxError, ValueError):
            continue
        if expected_calls > 1 and _top_level_call_count(module) < expected_calls:
            continue
        winners.append(candidate)
    if len(winners) == 1:
        return winners[0], True
    return text, False
return text, False

```

python/sclang/srt/function_call/pythonic_detector.py

移植 LFM2 修复中在 PythonicDetector 可观测的两个缺陷：非有限浮点序列化为 Infinity、不可转换参数连坐整块调用；改为按调用粒度捕获并跳过，`_get_parameter_value` 同时限定 Constant 为 JSON 可表示类型。

```

for call_index, call in enumerate(parsed.elts):
    if not isinstance(call.func, ast.Name):
        continue

```

```

function_name = call.func.id
# 工具未注册时按 SGLANG_FORWARD_UNKNOWN_TOOLS 决定跳过或放行
if function_name not in tool_indices:
    logger.warning(
        f"Model attempted to call undefined function: {function_name}"
    )
    if not envs.SGLANG_FORWARD_UNKNOWN_TOOLS.get():
        continue
# 每个 Call 独立转换：不可转换的参数以前会逃逸到外层 except,
# 把块内所有可解析的兄弟调用一并丢弃
try:
    arguments = {}
    for keyword in call.keywords:
        arguments[keyword.arg] = self._get_parameter_value(keyword.value)
    # allow_nan=False: 非有限浮点（如字面量 1e999 溢出为 inf）
    # 以前会被序列化成 Infinity，下游 JSON 解析器无法接受
    parameters = json.dumps(arguments, ensure_ascii=False, allow_nan=False)
except (ValueError, TypeError) as e:
    logger.warning(f"Skipping tool call {function_name}: {e}")
    continue
calls.append(
    ToolCallItem(
        tool_index=call_index,
        name=function_name,
        parameters=parameters,
    )
)
return StreamingParseResult(normal_text=normal_text, calls=calls)

```

评论区精华

该 PR 没有行内 review 评论，唯一审核是 APPROVED (JustinTong0323: “LGTM”)；3 条 issue 评论均为 CI 指令（[/tag-and-rerun-ci](#)、两次 [/rerun-failed-ci](#)）。真正的设计讨论记录在 PR body 与提交演进中：

1) 作者把第三类“模型写了非法 Python 时的恢复重写”明确标记为 “the debatable group; I am happy to drop them if you would rather keep the pressure on the model”，即恢复可能降低对模型输出质量的纠正压力，最终该组随 PR 合并，接受标准是“确定性、保值、ast 校验通过、歧义即拒绝”；2) 合并者 JustinTong0323 用最后一个提交（[753024d](#)）补上了一处审查暴露的作用域缺陷：[_restore_reserved_kwarg_names](#) 原本无条件执行，工具真实声明 [in_pyreservedkw_](#) 参数会被静默改回 `in`，修复后 [_recovery_candidates](#) 对经过改名处理的候选打标记、还原只作用于这些候选，并把 `rename` 与 `requote` 组合以覆盖 `from='sed -n ' 1,5p' f.py'` 这类叠加缺陷。

- 恢复型重写与严格拒绝的边界取舍 (design): 该组恢复最终随 PR 合并；接受标准是确定性、保值、ast 校验通过，且多个候选都能解析的歧义场景拒绝而非猜测。
- 保留字参数恢复的作用域缺陷修复 (correctness): [_recovery_candidates](#) 为经过 `rename` 的候选打标记，还原仅作用于这些候选的解码结果；`rename` 与 `requote` 按序组合执行。

风险与影响

- 风险：1) lfm2_detector.py 的 4 个重写 helper 都是字符级状态机扫描（引号、反斜杠转义、标识符 / 数字边界），对三重引号字符串、f-string 内部花括号、注释等未覆盖语法存在误判可能；缓解措施是所有候选必须通过 safe_ast_parse 校验，且只在原解析失败后触发，正常路径零开销。2) _escape_nested_quotes_in_strings 依赖 _split_top_level_calls 的括号计数作为“不吞兄弟调用”的不变量，若块内出现未配对括号，计数可能失真，恢复判定会变保守或失效。3) pythonic_detector.py 行为变更：bytes/ 复数等参数从“整块丢弃”变为“仅跳过该调用”，非有限浮点从“输出非法 JSON”变为“跳过调用”，对既有调用方是可见但合理的语义收紧。4) 测试覆盖：19 个回归用例大多走非流式 detect_and_parse，流式缓冲路径虽声明继承同一逻辑，但缺少针对恢复的流式专项用例。5) 性能：恢复阶梯只在解析失败后执行，最坏是对同一文本做多次线性扫描， $O(n)$ 量级，风险低。
- 影响：影响范围集中在 sglang/srt/function_call 包：Lfm2Detector 的合法调用不再被误丢、非法参数不再以“成功”状态输出、坏块中的好调用得以存活；PythonicDetector 也同步收紧了两处缺陷。对用户而言，LFM2/LFM2.5 的 SWE-agent / shell-command 场景工具调用成功率与参数可信度提升；对系统无 API、schema 或部署变更；对团队而言，这套“确定性、保值、ast 校验、歧义即拒绝”的恢复模式与 42-payload 差分对比 vLLM 的验证方法，可作为后续其他 pythonic 系检测器（llama4/olmo3）同类修复的模板。
- 风险标记：引号状态机复杂度高，嵌套引号恢复依赖调用数不变量，Pythonic 检测器行为变更，流式恢复路径测试覆盖偏弱

关联脉络

- 暂无明显关联 PR