

PR #28149 完整报告

sgl-project/sglang

Support GLM-4.7 function calling via structural tags

合并时间: 2026-06-14 14:57

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28149>

执行摘要

- 一句话: 为 GLM-4.7 启用结构标签指导的函数调用
- 推荐动作: 值得精读。该 PR 展示了如何为特定模型接入 xgrammar 原生结构标签的完整流程, 包括运行时探测、thinking 模式处理、以及优雅降级。其中的设计决策 (例如通过 lru_cache 缓存探测结果、在 get_structural_tag 中调用父类方法避免重复实现) 值得在其他模型检测器中借鉴。

功能与动机

GLM-4.7 MoE 函数调用检测器原先 `supports_structural_tag()` 硬编码为 `False`, 导致无法使用结构化 / 语法引导的工具调用, 只能依赖自由文本生成, 可靠性较低。PR 正文明确指出: "This forced these models to rely on free-form generation for function calls, which is less reliable."

实现拆解

实现分为以下步骤:

1. 运行时探测 xgrammar 可用性: 在文件 `glm47_moe_detector.py` 顶部新增 `_glm47_native_structural_tag_available()` 函数, 使用 `lru_cache` 缓存结果。通过调用 `get_model_structural_tag(model="glm_4_7", ...)` 并捕获异常来判断 xgrammar 是否注册了 `glm_4_7` 标签, 避免在 xgrammar 版本过旧时直接返回 `True` 导致后续崩溃。
2. 启用结构标签支持: 将 `supports_structural_tag()` 的返回值从 `False` 改为调用 `_glm47_native_structural_tag_available()`。新增 `get_structural_tag()` 方法, 在支持时调用父类方法, 不支持时返回 `None`。新增 `get_structural_tag_name()` 方法返回 `"glm_4_7"`, 映射到 xgrammar 的原生结构标签。
3. 处理 thinking 模式: `get_structural_tag()` 接受 `thinking_mode` 参数, 当 `thinking_mode=True` 时保留 `</think>` 推理前缀; 当 `False` 时由 `ReasonerGrammarBackend` 负责该前缀, 避免重复。
4. 更新导入依赖: 新增对 `functools.lru_cache`、`ToolChoice`、`StructuralTag`、`get_model_structural_tag` 等的导入, 确保新代码可用。
5. 新增单元测试: 在 `test_function_call_parser.py` 中添加两个测试方法。
`test_get_model_structural_tag` 验证结构标签在各种 `thinking_mode` 和 `tool_choice` 下能正确编译为 xgrammar 的 `grammar` 对象, 并检查序列化输出包含 `glm_xml`、`<tool_call>`、

</think> 等关键标记。test_required_tool_choice_falls_back_when_native_tag_is_unavailable 模拟 get_model_structural_tag 不可用（通过 patch），验证 supports_structural_tag() 返回 False、get_structural_tag() 返回 None，且 FunctionCallParser 在 tool_choice="required" 时能正确回退到 JSON Schema 约束。

关键文件：

- python/sglang/srt/function_call/glm47_moe_detector.py（模块 函数调用；类别 source；类型 core-logic；符号 _glm47_native_structural_tag_available, supports_structural_tag, get_structural_tag, get_structural_tag_name）：核心逻辑文件，新增运行时探测函数、启用结构标签支持、实现 get_structural_tag 和 get_structural_tag_name 方法。
- test/registered/unit/function_call/test_function_call_parser.py（模块 测试；类别 test；类型 test-coverage；符号 test_get_model_structural_tag, test_required_tool_choice_falls_back_when_native_tag_is_unavailable）：新增两个测试方法，覆盖结构标签正常编译和 xgrammar 不可用时的回退路径，确保核心逻辑的正确性。

关键符号：_glm47_native_structural_tag_available, supports_structural_tag, get_structural_tag, get_structural_tag_name, test_get_model_structural_tag, test_required_tool_choice_falls_back_when_native_tag_is_unavailable

关键源码片段

python/sglang/srt/function_call/glm47_moe_detector.py

核心逻辑文件，新增运行时探测函数、启用结构标签支持、实现 get_structural_tag 和 get_structural_tag_name 方法。

```
# 运行时探测 xgrammar 是否支持 glm_4_7 结构标签
# 使用 lru_cache 确保每次进程只探测一次
@lru_cache(maxsize=1)
def _glm47_native_structural_tag_available() -> bool:
    # "glm_4_7" 仅在较新的 xgrammar 中注册，所以导入可能成功但模型名不被识别
    # 探测一次，如果缺失则自动降级
    if get_model_structural_tag is None:
        return False
    try:
        get_model_structural_tag(
            model="glm_4_7", tools=[], tool_choice="auto", reasoning=False
        )
        return True
    except Exception:
        return False

class Glm47MoeDetector(BaseFormatDetector):
    # ... 原有代码 ...

    def supports_structural_tag(self) -> bool:
        # 返回运行时探测结果，而非硬编码 False
```

```

        return _glm47_native_structural_tag_available()

def get_structural_tag(
    self,
    tools: Union[List[Tool], None] = None,
    tool_choice: Union[ToolChoice, Literal["auto", "required"]] = "auto",
    thinking_mode: bool = False,
) -> Optional[StructuralTag]:
    if not self.supports_structural_tag():
        return None
    # 调用父类方法生成结构标签，父类会利用 get_structural_tag_name 获取模型名
    return super().get_structural_tag(
        tools=tools, tool_choice=tool_choice, thinking_mode=thinking_mode
    )

def get_structural_tag_name(self) -> str:
    # 返回 xgrammar 中注册的 glm_4_7 标签名
    return "glm_4_7"

```

test/registered/unit/function_call/test_function_call_parser.py

新增两个测试方法，覆盖结构标签正常编译和 xgrammar 不可用时的回退路径，确保核心逻辑的正确性。

```

def test_get_model_structural_tag(self):
    """GLM-4.7/GLM-5 使用 xgrammar 的原生 "glm_4_7" 结构标签。"""
    import xgrammar as xgr

    # 验证检测器支持结构标签且名称正确
    self.assertTrue(self.detector.supports_structural_tag())
    self.assertEqual(self.detector.get_structural_tag_name(), "glm_4_7")

    # thinking_mode=True 时保留 </think> 推理前缀
    structural_tag = self.detector.get_structural_tag(
        self.tools, thinking_mode=True
    )
    self.assertIsInstance(structural_tag, xgr.StructuralTag)
    serialized = structural_tag.model_dump_json()
    self.assertIn("glm_xml", serialized)
    self.assertIn("<tool_call>", serialized)
    self.assertIn("</think>", serialized)

    # thinking_mode=False 时去掉推理前缀（由 ReasonerGrammarBackend 处理）
    structural_tag = self.detector.get_structural_tag(
        self.tools, thinking_mode=False
    )
    self.assertIsInstance(structural_tag, xgr.StructuralTag)

    # tool_choice="required" 也必须能编译成 grammar
    structural_tag = self.detector.get_structural_tag(

```

```

        self.tools, thinking_mode=True, tool_choice="required"
    )
    self.assertIsInstance(structural_tag, xgr.StructuralTag)
    self.assertIsInstance(
        xgr.Grammar.from_structural_tag(structural_tag), xgr.Grammar
    )

def test_required_tool_choice_falls_back_when_native_tag_is_unavailable(self):
    """当 xgrammar 不支持 glm_4_7 时，supports_structural_tag 返回 False，
    get_structural_tag 返回 None，tool_choice="required" 回退到 JSON Schema。"""
    from unittest.mock import patch
    from sglang.srt.function_call.function_call_parser import FunctionCallParser
    from sglang.srt.function_call.glm47_moe_detector import (
        _glm47_native_structural_tag_available,
    )

    # 模拟 get_model_structural_tag 不可用（例如 xgrammar 版本过旧）
    with patch(
        "sglang.srt.function_call.glm47_moe_detector.get_model_structural_tag",
        None,
    ):
        _glm47_native_structural_tag_available.cache_clear()
        self.assertFalse(self.detector.supports_structural_tag())
        self.assertIsNone(self.detector.get_structural_tag(self.tools))

        # 需要 tool_choice="required" 时，回退到 json_schema 约束
        parser = FunctionCallParser(self.tools, "glm47")
        constraint = parser.get_structure_constraint("required")
        self.assertIsNotNone(constraint)
        self.assertEqual("json_schema", constraint[0])
        _glm47_native_structural_tag_available.cache_clean() # 清理缓存避免影响其他测试

```

评论区精华

唯一的 review 评论来自 [gemini-code-assist\[bot\]](#)，指出如果 xgrammar 未安装或版本过旧，`supports_structural_tag()` 返回 `True` 会导致 `get_structural_tag()` 返回 `None`，进而使解析器调用 `structure_info()`，而该方法会抛出 `NotImplementedError`，导致约束失败。

解决：作者后来通过添加 `_glm47_native_structural_tag_available()` 运行时探测函数，在 `supports_structural_tag()` 中返回探测结果，确保在 xgrammar 不可用时返回 `False`，避免后续错误。该探测函数使用 `lru_cache` 缓存结果，每次进程只探测一次。

- xgrammar 不可用时可能导致 `NotImplementedError (correctness)`：作者通过添加 `_glm47_native_structural_tag_available` 运行时探测函数解决，该函数在调用 `get_model_structural_tag` 并捕获异常，返回布尔值供 `supports_structural_tag` 使用。同时使用 `lru_cache` 避免重复探测。

风险与影响

- 风险:

1. xgrammar 版本兼容性: `_glm47_native_structural_tag_available()` 通过调用 `get_model_structural_tag` 并捕获异常来探测, 但该探测可能因为其他原因 (如网络问题) 而失败, 导致即使 xgrammar 支持也无法启用。不过由于探测在进程启动时执行一次, 且异常捕获广泛, 风险较低。
2. glm_4_7 标签生命周期: 若未来 xgrammar 删除或重命名该标签, 探测会捕获异常并自动降级, 不会崩溃。但需要保持同步更新。
3. thinking_mode 处理一致性: `thinking_mode=False` 时, 结构标签中不包含 `</think>` 前缀, 但 `ReasonerGrammarBackend` 需要正确接管。若配置不当可能导致推理格式错误。
4. 测试覆盖: 两个测试方法覆盖了正常路径和回退路径, 但未覆盖中间件集成测试, 例如实际调用推理引擎验证生成的函数调用格式。
 - 影响: 影响范围: 仅影响 GLM-4.7 MoE 模型 (及潜在的 GLM-5 模型) 的函数调用行为。用户无需手动迁移, 原有自由文本调用方式不受影响。

影响程度: 正面——为 GLM-4.7 用户提供更可靠的函数调用能力, 约束生成能减少解析错误和格式异常。

系统影响: 无性能或安全影响, 变更仅涉及检测器的逻辑分支。

- 风险标记: 依赖 xgrammar 版本, 运行时探测无法覆盖所有异常场景

关联脉络

- 暂无明显关联 PR