

PR #21722 完整报告

sgl-project/sglang

feat: use structural tags to enable strict tool calling and reasoning for more models

合并时间: 2026-05-04 17:30

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/21722>

执行摘要

- 一句话: 升级 xgrammar 并引入内置 structural tags 支持更多模型 tool calling
- 推荐动作: 建议团队精读此 PR, 尤其是 `get_structure_constraint` 的重构和 `base_format_detector.py` 中 `get_structural_tag` 的集中化设计, 这为未来添加更多模型的原生结构化约束奠定了良好基础。同时注意监控 Kimi 内置 tag 的 xgrammar 上游修复进度, 以便及时重新启用。

功能与动机

PR body 明确指出升级 xgrammar 到 v0.2.0 以利用其 built-in `structural_tags` 特性, 为更多模型提供结构化生成, 尤其是 tool calling 场景。性能基准测试 (BFCL-v3) 显示开启 structural tags 后正确率显著提升。此外, 社区反馈也期望支持更多模型 (如 minimax) 的结构化调用。

实现拆解

1. 升级依赖并处理可选导入: 在 `pyproject.toml` 中将 xgrammar 从 0.1.32 升级到 0.2.0, 并在 `base_format_detector.py` 中使用 `try/except ImportError` 保护 `xgrammar.StructuralTag` 和 `get_model_structural_tag` 的导入, 避免 XPU 等无 xgrammar 环境启动失败。
2. 新增基类方法: 在 `BaseFormatDetector` 中添加 `get_structural_tag_name()` (子类重写返回模型名称) 和 `get_structural_tag()` (调用 `get_model_structural_tag` 生成原生 tag), 子类只需提供名称即可复用统一逻辑。
3. 重构约束生成逻辑: `FunctionCallParser.get_structure_constraint()` 优先尝试 `detector.get_structural_tag()`, 若返回非 `None` 则直接使用原生 tag; 否则回退到旧有的 `legacy_structural_tag` 路径 (需要 `supports_structural_tag()` 为 `True`); 最后才是 JSON schema fallback。同时处理 `thinking_mode` 参数的传递, 并在存在 `ReasonerGrammarBackend` 时不要求 xgrammar 包含 `reasoning prefix`。
4. 新增模型 detector: 添加 `deepseekv4_detector.py`, 继承 `DeepSeekV32Detector` 但使用 `< | DSML | tool_calls >` 标签; `qwen3_coder_detector.py` 开启 `supports_structural_tag` 并返回 `qwen_3_coder` 模型名; `deepseekv32_detector.py`、`gpt_oss_detector.py` 等也添加了 `get_structural_tag_name`。

5. 修复 speculative decoding 兼容性: spec_utils.py 中的 traverse_tree 内部循环在调用 xgrammar 前将 0 维 tensor 显式转换为 Python int, 以适配 xgrammar 0.2.0 的严格类型签名。
6. 测试配套: 在 test_function_call_parser.py 中新增 test_get_model_structural_tag 和 TestDeepSeekV4Detector 等测试, 覆盖原生 structural tag 的生成与解析; 新增 test_spec_utils_traverse_tree.py 回归测试, 确保 tensor 转换正确。

关键文件:

- python/sglang/srt/function_call/function_call_parser.py (模块 函数调用; 类别 source ; 类型 core-logic; 符号 get_structure_constraint, get_legacy_structural_tag, get_structural_tag) : 核心解析器: 重构 get_structure_constraint 方法, 引入基于 get_structural_tag 的三级回退机制; 重命名 get_structure_tag 为 get_legacy_structural_tag。
- python/sglang/srt/function_call/base_format_detector.py (模块 函数调用; 类别 source ; 类型 dependency-wiring; 符号 get_structural_tag_name, get_structural_tag) : 基类 : 添加 get_structural_tag_name 和 get_structural_tag 方法, 集中实现 xgrammar 桥接逻辑, 所有子类只需返回模型名称。
- python/sglang/srt/function_call/deepseekv4_detector.py (模块 函数调用; 类别 source ; 类型 core-logic; 符号 DeepSeekV4Detector, init, get_structural_tag_name) : 新增 DeepSeek V4 检测器, 继承 V3.2 但使用 DSML 标签, 支持两种参数格式 (XML 或 JSON) , 并返回模型名 'deepseek_v4'。
- test/registered/unit/function_call/test_function_call_parser.py (模块 测试; 类别 test; 类型 test-coverage; 符号 TestDeepSeekV4Detector, test_get_model_structural_tag, test_detect_and_parse_xml_format, test_detect_and_parse_json_format) : 大规模测试 新增: 覆盖 DeepSeek V4 detector 的 XML/JSON 格式解析、streaming 解析、以及 get_structural_tag 生成测试
- test/registered/unit/spec/test_spec_utils_traverse_tree.py (模块 推测解码; 类别 test; 类型 test-coverage; 符号 TestTraverseTreePassesIntsToGrammar, _record_grammar, record_accept, record_fill) : 回归测试: 验证 spec_utils.traverse_tree 在 xgrammar 0.2.0 下传递 int 而非 tensor, 避免类型错误

关键符号: BaseFormatDetector.get_structural_tag_name, BaseFormatDetector.get_structural_tag, FunctionCallParser.get_structure_constraint, FunctionCallParser.get_legacy_structural_tag, DeepSeekV4Detector.init, DeepSeekV4Detector.get_structural_tag_name, Qwen3CoderDetector.get_structural_tag_name, DeepSeekV32Detector.get_structural_tag_name, GptOssDetector.get_structural_tag_name

关键源码片段

python/sglang/srt/function_call/function_call_parser.py

核心解析器：重构 `get_structure_constraint` 方法，引入基于 `get_structural_tag` 的三级回退机制；重命名 `get_structure_tag` 为 `get_legacy_structural_tag`。

```
# python/sglang/srt/function_call/function_call_parser.py
```

```
# 重构后的 get_structure_constraint 方法（部分）
```

```
def get_structure_constraint(
    self,
    tool_choice: Union[ToolChoice, Literal["auto", "required"]],
    parallel_tool_calls: bool = True,
    thinking_mode: bool = False,
) -> Optional[ToolCallConstraint]:
    is_required = tool_choice == "required" or isinstance(tool_choice, ToolChoice)
    should_constrain_auto = tool_choice == "auto" and (
        any(tool.function.strict for tool in self.tools)
        or self.tool_strict_level >= ToolStrictLevel.FUNCTION
    )

    # 1. 优先使用模型原生 structural_tag (xgrammar 0.2.0 内建)
    # 例如 DeepSeek V4 / Qwen3 Coder 可通过 get_structural_tag_name 返回模型名
    try:
        if is_required or should_constrain_auto:
            structural_tag = self.detector.get_structural_tag(
                tools=self.tools,
                thinking_mode=thinking_mode,
                tool_choice=tool_choice,
            )
            if structural_tag is not None:
                return ("structural_tag", structural_tag)

        # 2. 回退到 legacy structural_tag (旧的 parser 内建约束)
        if self.detector.supports_structural_tag():
            tag = self.get_legacy_structural_tag(at_least_one=is_required)
            return ("structural_tag", tag)

    except Exception:
        # 若 xgrammar 调用失败（如模型名不匹配），继续回退
        pass

    # 3. 最后回退到 JSON schema
    if tool_choice == "required" or isinstance(tool_choice, ToolChoice):
        json_schema = get_json_schema_constraint(
            self.tools, tool_choice, parallel_tool_calls=parallel_tool_calls
        )
        return ("json_schema", json_schema)
    return None
```

python/sglang/srt/function_call/base_format_detector.py

基类：添加 `get_structural_tag_name` 和 `get_structural_tag` 方法，集中实现 xgrammar 桥接逻辑，所有子类只需返回模型名称。

```
# python/sglang/srt/function_call/base_format_detector.py

# 在文件顶部，使用 try/except 保护 xgrammar 导入
# 使得无 xgrammar 的 XPU 环境也能正常加载模块
try:
    from xgrammar import StructuralTag, get_model_structural_tag
except ImportError:
    StructuralTag = Any # type: ignore[misc, assignment]
    get_model_structural_tag = None

class BaseFormatDetector(ABC):
    # ... 其他方法 ...

    def get_structural_tag_name(self) -> Optional[str]:
        """子类重写返回 XGrammar 模型名称（如 "deepseek_v4"），
        基类默认返回 None，表示不支持原生 structural tag。"""
        return None

    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]:
        """
        生成模型原生 XGrammar structural tag。
        当 --reasoning-parser 配置时，SGLang 的 ReasonerGrammarBackend
        会处理 <think>...</think> 前缀，因此此处传入 reasoning=thinking_mode
        但只在不需要外层推理时才让 xgrammar 包含 reasoning prefix。
        """
        structural_tag_name = self.get_structural_tag_name()
        # 既没有模型名，也没有 xgrammar 可用时直接返回 None
        if not structural_tag_name or get_model_structural_tag is None:
            return None

        # 将 SGLang 的 Tool 对象转换为 dict
        converted_tools = [tool.model_dump() for tool in tools or []]
        converted_tool_choice = (
            tool_choice.model_dump()
            if isinstance(tool_choice, ToolChoice)
            else tool_choice
        )
        return get_model_structural_tag(
            model=structural_tag_name,
            tools=converted_tools,
            tool_choice=converted_tool_choice,
```

```
        reasoning=thinking_mode,
    )
```

python/sglang/srt/function_call/deepseekv4_detector.py

新增 DeepSeek V4 检测器，继承 V3.2 但使用 DSML 标签，支持两种参数格式（XML 或 JSON），并返回模型名 'deepseek_v4'。

```
# python/sglang/srt/function_call/deepseekv4_detector.py
import logging

from sglang.srt.function_call.deepseekv32_detector import DeepSeekV32Detector

logger = logging.getLogger(__name__)

class DeepSeekV4Detector(DeepSeekV32Detector):
    """
    检测 DeepSeek V4 模型函数调用格式。
    使用 DSML 标签（如 < | DSML | tool_calls>）而非 V3.2 的 < | DSML | function_calls>。
    支持两种参数格式：
    1. XML Parameter Tags: < | DSML | parameter name="...">value</ | DSML | parameter>
    2. Direct JSON: { "param_name": "value" } 直接放在 < | DSML | invoke> 内
    """

    def __init__(self):
        super().__init__()
        # V4 使用 tool_calls 而非 function_calls
        self.bot_token = "< | DSML | tool_calls>"
        self.eot_token = "</ | DSML | tool_calls>"
        self.function_calls_regex = r"< | DSML | tool_calls>(.*?)</ | DSML | tool_calls>"

    def get_structural_tag_name(self) -> str:
        # 返回 xgrammar 内建模型名称，用于 get_model_structural_tag
        return "deepseek_v4"
```

评论区精华

Review 中主要讨论了以下几个关键点：

- 依赖版本问题：JustinTong0323 指出 xgrammar==0.2.0 在发布前无法在 PyPI 上安装，导致 CI 失败（后已发布）。
- XPU 兼容性：JustinTong0323 发现 base_format_detector.py 中直接 import xgrammar 会导致无 xgrammar 的 XPU 环境启动失败，要求保护导入，最终采用了 try/except 方案。
- Kimi 内置 tag 缺少 section wrapper：JustinTong0323 发现 xgrammar 0.2.0 的 Kimi built-in grammar 在 tool_choice="auto" 时缺少 <|tool_calls_section_begin|> 包装，导致 SGLang 解析器丢弃生成的 tool call，最终决定暂不为 Kimi 启用内置 tag，等待 xgrammar 修复。

- DeepSeek V4 detector 未注册到枚举: JustinTong0323 指出新增的 DeepSeek V4 detector 没有被加入 ToolCallParserEnum, 因此无法通过运行时选择使用; Seven-Streams 解释是因为 V4 的 begin 标签与 V3.2 不同 (< | DSML | tool_calls> vs < | DSML | function_calls>)。
- thinking_mode 默认值: JustinTong0323 批评将 thinking_mode 默认设为 True 会导致非 reasoning 模型生成错误格式, 最终修正为从 chat_template_kwargs 中正确推导。
- 设计集中化: Ubospica 和 JustinTong0323 建议将 `get_structural_tag` 的实现集中到基类, 子类只提供模型名称, 最终采纳并重构。
 - 依赖版本未发布导致安装失败 (infra): 等待 xgrammar 0.2.0 发布后重新尝试; AgainstEntropy 确认已可安装。
 - XPU 环境因直接导入 xgrammar 启动失败 (security): 采用 try/except 导入, 设置 StructuralTag = Any, get_model_structural_tag = None。
 - Kimi 内置 structural tag 缺少 section wrapper (correctness): 暂不为 Kimi 启用内置 tag, 保留在 legacy 路径; 等待 xgrammar 修复 (issue #622)。
 - DeepSeek V4 detector 未注册到解析器枚举 (design): 代码中已添加注册, 但 reviewer 仍建议确保正确性 (最终已加入)。
 - thinking_mode 默认值不当 (correctness): 修改为从 chat_template_kwargs 中正确解析 thinking_mode, 并在存在 ReasoningParser 时不传递 reasoning 给 xgrammar。

风险与影响

- 风险:
 1. 依赖升级风险: xgrammar 0.2.0 可能与其他依赖 (如 NPU 工作流使用的 0.1.25) 冲突, PR 中已对 NPU 工作流也做了升级 (从 0.1.25 跳到 0.2.0), 但未充分验证可能引入不兼容。
 2. XPU 导入失败风险: 虽然使用了 try/except 保护导入, 但若 xgrammar 的 StructuralTag 被用作类型注解且运行时缺失, 仍可能导致某些路径抛出 NameError (当前代码仅在运行时方法中引用, 风险较低)。
 3. Kimi/Kimi 解析弃用: 由于 xgrammar 内置 Kimi 语法缺少 section wrapper, 当前对 Kimi 禁用了内置 structural tag, 但若未来 xgrammar 修复后忘记重新启用, 可能导致 Kimi 工具调用约束退化。
 4. 测试覆盖不全: PR 主要测试了 Qwen3 Coder 和 DeepSeek V4, 但 Kimi K2 和 GPT-OSS 的 get_structural_tag 覆盖未添加单元测试, 可能隐藏问题。
 5. 核心解析路径变更: get_structure_constraint 的重构改变了工具调用约束的优先级, 若某个 detector 的 get_structural_tag 抛出异常 (如模型名称不匹配), 将导致请求 500 错误 (已有 try 块但未处理所有异常)。- 影响: 功能影响: 为 DeepSeek V4、Qwen3 Coder 等模型启用了原生结构化工具调用, 可显著提高工具调用格式正确率 (BFCL 测试显示提升 5-10%)。系统影响: 依赖升级可能影响安装流程; NPU 工作流可能因版本跳跃需要额外验证。团队影响: 函数调用解析器的架构更加统一, 后续添加新模型只需在 detector 中实现 get_structural_tag_name 即可。用户影响: 使用相关模型时工具调用可靠性提升, 但 tool_choice="auto" 且未启用 strict 模式时行为不变。- 风险

标记：依赖升级未完全验证，XPU 兼容性依赖保护，Kimi 内置 tag 暂禁需跟踪上游修复，核心解析路径新异常未覆盖，部分 detector 缺少 get_structural_tag 测试

关联脉络

- PR #25600 Add MiniCPM5 tool call parser for XML-style function calls: 同样涉及 tool calling 解析器扩展，修改了 function_call_parser.py 和 template_detection.py，与本 PR 的解析器重构有重叠逻辑。
- PR #26085 drop FutureIndices wrapper class: 修改了 speculative decoding 相关模块，与本 PR 对 spec_utils.py 的 tensor 类型修复有间接关联。