

PR #46610 完整报告

vllm-project/vllm

[Frontend] Add Streaming Parser Engine and new Kimi k2.5/k2.6/k2.7 Parser

合并时间: 2026-06-30 15:53

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/46610>

执行摘要

- 一句话: 新增 Kimi K2 流式解析引擎和 Parser
- 推荐动作: 值得精读。该 PR 展示了如何基于 ParserEngine 构建新模型解析器, 并成功将旧的独立解析器迁移到统一框架, 对后续模型支持有示范作用。

功能与动机

为了支持 Kimi K2 模型系列 (k2.5/k2.6/k2.7) 的工具调用和推理内容解析, 并统一到新的 ParserEngine 框架中, 避免重复实现。如 PR body 所述, 需要兼容 tool_choice=required 的流式与非流式调用。

实现拆解

1. 新增 vllm/parser/kimi_k2.py, 定义 kimi_k2_config 函数返回 ParserEngineConfig, 配置有限状态机, 包括 reasoning 和 tool call 标记的转换; 定义 KimiK2Parser 类继承自 ParserEngine, 提供 _emit_name_delta、_handle_tool_end、_handle_arg_chunk 等方法。
2. 重写 vllm/tool_parsers/kimi_k2_tool_parser.py, 改为继承 KimiK2ParserToolAdapter (由 make_adapters 生成), 仅保留 adjust_request 方法, 复用 ParserEngine 逻辑。
3. 重写 vllm/reasoning/kimi_k2_reasoning_parser.py, 直接设为 KimiK2ParserReasoningAdapter 别名, 所有接口委托给 ParserEngine。
4. 在 vllm/parser/engine/registered_adapters.py 中通过 make_adapters(KimiK2Parser) 生成适配器并导出。
5. 测试配套: 在 tests/parser/engine/trace_builder.py 中添加 Kimi K2 的词汇表和场景生成函数, 注册到构建器字典; 修改 tests/reasoning/test_kimi_k2_reasoning_parser.py 适配新的 parser 属性访问方式。

关键文件:

- vllm/parser/kimi_k2.py (模块 解析器; 类别 source; 类型 core-logic; 符号 kimi_k2_config, KimiK2Parser, init, _extract_tool_id_and_name): 核心新增文件, 定义 Kimi K2 流式解析逻辑
- vllm/tool_parsers/kimi_k2_tool_parser.py (模块 工具解析器; 类别 source; 类型 dependency-wiring; 符号 KimiK2ToolParser, init, extract_tool_calls, _extract_content): 大幅简化, 复用 ParserEngine 适配器

- vllm/reasoning/kimi_k2_reasoning_parser.py (模块 推理解析器; 类别 source; 类型 dependency-wiring; 符号 KimiK2ReasoningParser, init, reasoning_start_str, reasoning_end_str) : 改为别名, 委托给 ParserEngine
- vllm/parser/engine/registered_adapters.py (模块 解析器注册; 类别 source; 类型 dependency-wiring) : 注册 KimiK2Parser 适配器
- tests/parser/engine/trace_builder.py (模块 测试生成器; 类别 test; 类型 test-coverage ; 符号 _kimi_k2_tool_segments, _kimi_k2_segments, _build_kimi_k2) : 添加 Kimi K2 测试场景与词汇表
- tests/reasoning/test_kimi_k2_reasoning_parser.py (模块 推理解析测试; 类别 test; 类型 test-coverage; 符号 test_parser_selection_thinking_enabled, test_parser_selection_thinking_disabled, test_streaming_end_token_id_buffered, test_streaming_tool_section_id_buffered) : 适配新的 ParserEngine 结构

关键符号: kimi_k2_config, KimiK2Parser.init, KimiK2Parser._emit_name_delta, KimiK2Parser._handle_tool_end, KimiK2Parser._handle_arg_chunk, KimiK2Parser._extract_tool_id_and_name, KimiK2Parser._extract_args_json, KimiK2ToolParser.adjust_request, KimiK2ReasoningParser (alias), _kimi_k2_tool_segments, _kimi_k2_segments, _build_kimi_k2

关键源码片段

vllm/tool_parsers/kimi_k2_tool_parser.py

大幅简化, 复用 ParserEngine 适配器

```
# vllm/tool_parsers/kimi_k2_tool_parser.py
from vllm.entrypoints.openai.chat_completion.protocol import ChatCompletionRequest
from vllm.entrypoints.openai.responses.protocol import ResponsesRequest
from vllm.parser.engine.registered_adapters import KimiK2ParserToolAdapter
```

```
class KimiK2ToolParser(KimiK2ParserToolAdapter): # type: ignore[valid-type, misc]
    """Tool parser for Kimi K2 models.
```

```
    Inherits all streaming logic from the ParserEngine-based adapter.
    """
```

```
    structural_tag_model = "kimi"
```

```
    def adjust_request(
        self,
        request: ChatCompletionRequest | ResponsesRequest,
    ) -> ChatCompletionRequest | ResponsesRequest:
        # When tools are enabled, keep special tokens as literal text
        # so the parser can see markers like <|tool_call_begin|>
        if request.tools and request.tool_choice != "none":
            request.skip_special_tokens = False
        return request
```

tests/parser/engine/trace_builder.py

添加 Kimi K2 测试场景与词汇表

```
# tests/parser/engine/trace_builder.py

# Kimi K2 特殊词汇表, 将标记映射为 token ID
_KIMI_K2_VOCAB: dict[str, int] = {
    "<think>": 50,
    "</think>": 51,
    "<ltool_calls_section_beginl>": 60,
    "<ltool_calls_section_endl>": 61,
    "<ltool_call_beginl>": 62,
    "<ltool_call_endl>": 63,
    "<ltool_call_argument_beginl>": 64,
}

def _kimi_k2_tool_segments(
    tool_calls: list[ToolCallSpec],
) -> list[tuple[str, bool]]:
    """生成工具调用标记序列, 每个标记附带是否为 special token 的布尔值"""
    segs: list[tuple[str, bool]] = [("<ltool_calls_section_beginl>", True)]
    for index, tc in enumerate(tool_calls):
        # 将参数转为紧凑 JSON
        args = json.dumps(tc.arguments, ensure_ascii=False, separators=(",", ":"))
        segs.extend([
            ("<ltool_call_beginl>", True),
            # 函数 ID 格式: functions.<name>:<index>
            (f"functions.{tc.name}:{index}\n", False),
            ("<ltool_call_argument_beginl>", True),
            (args, False),
            ("<ltool_call_endl>", True),
        ])
    segs.append(("<ltool_calls_section_endl>", True))
    return segs

def _kimi_k2_segments(scenario: Scenario) -> list[tuple[str, bool]]:
    """构建完整输出段序列: 可选 reasoning + 可选 content + 可选 tool calls"""
    segs: list[tuple[str, bool]] = []
    if scenario.reasoning is not None:
        segs.append(("<think>", True))
        segs.append((scenario.reasoning, False))
    if scenario.content is not None or scenario.tool_calls is not None:
        segs.append(("</think>", True))
    if scenario.content is not None:
        segs.append((scenario.content, False))
    if scenario.tool_calls is not None:
        segs.extend(_kimi_k2_tool_segments(scenario.tool_calls))
    return segs
```

评论区精华

在 review 中, sfeng33 指出 tool_id 解析时应使用 `removeprefix('functions.')` 以兼容不同前缀的 `functions.`, 建议仅在 `functions.` 开头时去除。sfeng33 还建议同时支持 `enable_thinking` 和 `thinking` 参数以兼容上游配置。chaunceyjiang 回复已修改 (Done)。

- tool_id 解析去除 `functions.` 前缀 (correctness): chaunceyjiang 回复 Done, 已修改。
- 同时支持 `enable_thinking` 和 `thinking` 参数 (design): 未收到明确回复, 但 PR 已合并, 可能已处理或计划后续跟进。

风险与影响

- 风险: 主要风险:
 1. 旧版 KimiK2ToolParser 和 KimiK2ReasoningParser 的完整实现被删除, 如果存在外部直接引用内部符号 (如 `_start_token_id`) 可能破坏兼容性; 测试中已经适配新属性。
 2. ParserEngine 框架本身较新, 可能存在边缘情况处理不完善。
 3. 配置键名称与旧版不一致可能导致迁移困惑。 - 影响: 影响范围: 仅影响 Kimi K2 模型用户, 且改进了解析可靠性; 对系统影响较小, 因为基于已有的 ParserEngine 扩展。开发团队因此获得了可复用的 Kimi 模型解析器模板。 - 风险标记: 旧代码完全删除, 测试覆盖变更, 配置键兼容性, ParserEngine 框架依赖

关联脉络

- PR #44135 Unknown (mentioned as bug report for tool_id parsing): 该 PR 的 review 中提及此 issue, 与 tool_id 解析修复相关。