

PR #35963 完整报告

sgl-project/sglang

Add Spark3 Model

合并时间: 2026-08-26 07:24

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/35963>

执行摘要

- 一句话: 新增 Spark3 模型架构支持与工具调用解析器
- 推荐动作: 值得精读。面向模型接入开发者, 重点看三处: Spark3Config 的 layer_types 与两套 rope_parameters 默认策略; models/spark3.py 的滑动窗口语义换算与 head-wise 输出门控实现; Spark3Detector 的流式原子输出与类型转换回退。建议在合并后跟进模型 E2E 精度测试与 1M context 压测。

功能与动机

PR body 明确目标是提供 "native support for the Spark 3 model architecture in SGLang", 并列多项卖点: 效率优先的架构 ("Sliding Window Attention (SWA) and other structural optimizations")、"Native 1M Context"、更强的 Coding 与 Agent 能力 ("Strong Coding & Agent Capabilities"), 以及可控思考预算 ("configurable reasoning levels — none, low, medium, and high")。核心动机是让 Spark3 1.7B/4B 模型的长上下文编码与工具调用场景能在 SGLang 上直接运行, 与近期多个模型接入 PR 一脉相承。

实现拆解

1. 配置层: 新增 `python/sglang/srt/configs/spark3.py`, 定义 `Spark3Config` (继承 `PretrainedConfig`, `model_type = "spark3"`)。关键默认策略: `layer_types` 默认按 $(i + 1) \% 4$ 每 4 层插入 1 个 `full_attention`, 其余为 `sliding_attention`; `rope_parameters` 提供两套默认值, `full attention` 用 `rope_theta = 5000000` 与 `partial_rotary_factor = 0.25`, `sliding attention` 用 `rope_theta = 10000` 与全量旋转。同时在 `python/sglang/srt/configs/__init__.py` 导出, 并在 `python/sglang/srt/utils/hf_transformers/common.py` 注册到 HF 配置注册表, 保证从 checkpoint 加载时能自动识别 `spark3` 类型。
2. 模型层: 新增 `python/sglang/srt/models/spark3.py`, 实现 `Spark3ForCausalLM`。核心设计包括: `_get_attention_sliding_window_size` 将 HF 的包含式滑动窗口换算为 SGLang 的排除式语义 (`sliding_window - 1`); `Spark3Attention` 使用 `QKVParallelLinear` 支持 GQA, 按 `attn_tp_size` 切分 Q/KV head, 并实现 `headwise_attn_output_gate` (逐 head 门控注意力输出) 与 `partial_rotary_factor` 部分旋转; `Spark3MLP` 采用 `MergedColumnParallelLinear + GeluAndMul` 的 gated MLP 结构。模型层通过 `make_layers` 与 `get_layer_id` 适配 TP/PP 切分, 接入 `RadixAttention` 与 `split prefill` (`is_dp_attention_enabled`) 路径, 并通过 `default_weight_loader` 加载权重。

3. 工具调用层：新增 `python/sglang/srt/function_call/spark3_detector.py`，实现继承 `BaseFormatDetector` 的 `Spark3Detector`。解析器通过 `ARG_PAIR_PATTERN` 正则提取 `<arg_key>/<arg_value>` 键值对，`_convert_value` 依据工具声明的 JSON Schema 类型将文本转为 `int`、`float`、`bool`、`list`、`dict`，失败时回退原文；流式模式下完整块原子输出，避免 XML 片段被暴露为 JSON 增量。随后在 `python/sglang/srt/function_call/function_call_parser.py` 将 `Spark3Detector` 注册到枚举的 `"spark"` 名称下。
4. 测试配套：新增 `test/registered/unit/function_call/test_spark3_detector.py` (202 行)，覆盖注册关系、多调用非流式解析、类型转换与 `"null"` 语义、未知工具策略 (`SGLANG_FORWARD_UNKNOWN_TOOLS`)、流式部分标记与终止刷新，并注册为 CPU CI (`base-a-test-cpu`)。注意该 PR 没有模型侧的 E2E 测试，PR body 的 MMLU-Pro 数据来自内部 benchmark。

关键文件：

- `python/sglang/srt/models/spark3.py` (模块 模型实现；类别 source；类型 core-logic；符号 `_get_attention_sliding_window_size`, `Spark3MLP`, `Spark3Attention`, `Spark3DecoderLayer`)：Spark3 模型核心实现 (564 行)，包含 SWA/full attention 交错、head-wise 输出门控、TP/PP 并行与 checkpoint 权重加载，是本 PR 的主体。
- `python/sglang/srt/function_call/spark3_detector.py` (模块 工具解析；类别 source；类型 core-logic；符号 `Spark3Detector`, `_parse_tool_call_xml`, `_convert_value`, `_get_param_type`)：新增 Spark3 工具调用解析器，解析 XML-KV 协议并处理流式边界，是 agent 场景的关键配套。
- `python/sglang/srt/configs/spark3.py` (模块 模型配置；类别 source；类型 core-logic；符号 `Spark3Config`, `init`)：定义 `Spark3Config`，承载模型维度、`layer_types` 默认布局与两套 RoPE 参数，是模型可加载的前提。
- `test/registered/unit/function_call/test_spark3_detector.py` (模块 单元测试；类别 test；类型 test-coverage；符号 `TestSpark3DetectorDetectAndParse`, `test_spark3_parser_is_registered`, `test_nonstream_pares_multiple_calls_and_preserves_normal_text`, `test_null_and_conversion_fallbacks_match_spark3_protocol`)：唯一测试配套，覆盖解析器注册、类型转换、未知工具与流式边界，但未覆盖模型加载 / 精度。
- `python/sglang/srt/function_call/function_call_parser.py` (模块 解析器注册；类别 source；类型 dependency-wiring)：将 `Spark3Detector` 注册到全局 `ToolCallParserEnum` 的 `"spark"` 名称，供用户通过 `--tool-call-parser spark` 启用。
- `python/sglang/srt/configs/__init__.py` (模块 配置导出；类别 source；类型 dependency-wiring)：导出 `Spark3Config`，保证 `from sglang.srt.configs import Spark3Config` 可用。
- `python/sglang/srt/utils/hf_transformers/common.py` (模块 模型注册；类别 source；类型 core-logic)：将 `Spark3Config` 注册进 HF 配置注册表，使 SGLang 能从 checkpoint 自动识别 `spark3` 模型类型。

关键符号：`_get_attention_sliding_window_size`, `Spark3MLP.forward`, `Spark3Attention.init`, `Spark3Attention.forward`, `Spark3DecoderLayer.forward`, `Spark3Model.forward`, `Spark3ForCausalLM.forward`, `Spark3Config.init`, `Spark3Detector.detect_and_parse`, `Spark3Detector.parse_streaming_increment`,

_parse_tool_call_xml, _convert_value, _get_param_type

关键源码片段

python/sglang/srt/models/spark3.py

Spark3 模型核心实现 (564 行), 包含 SWA/full attention 交错、head-wise 输出门控、TP/PP 并行与 checkpoint 权重加载, 是本 PR 的主体。

```
# 与 HF 实现保持一致: HF 的 sliding window 语义是包含最后一个 token 的,
# 而 SGLang 假设为排除式窗口, 因此这里减 1, 避免注意力范围多出一个位置。
def _get_attention_sliding_window_size(config):
    return config.sliding_window - 1
```

```
class Spark3MLP(nn.Module):
    def __init__(
        self,
        hidden_size: int,
        intermediate_size: int,
        quant_config: Optional[QuantizationConfig] = None,
        prefix: str = "",
        reduce_results: bool = True,
    ) -> None:
        super().__init__()
        # gated MLP: gate 与 up 合并为一路 MergedColumnParallelLinear,
        # down 投影按需 reduce, 支持 TP 下跨 rank 归约。
        self.gate_up_proj = MergedColumnParallelLinear(
            hidden_size,
            [intermediate_size] * 2,
            bias=False,
            quant_config=quant_config,
            prefix=add_prefix("gate_up_proj", prefix),
        )
        self.down_proj = RowParallelLinear(
            intermediate_size,
            hidden_size,
            bias=False,
            quant_config=quant_config,
            prefix=add_prefix("down_proj", prefix),
            reduce_results=reduce_results,
        )
        self.act_fn = GeluAndMul()

    def forward(self, x, forward_batch=None):
        gate_up, _ = self.gate_up_proj(x)
        # GeluAndMul 在激活的同时完成 gate 与 up 的逐元素乘法,
        # 省去一次中间 tensor 的物化。
        x = self.act_fn(gate_up)
        x, _ = self.down_proj(x)
```

```
return x
```

python/sglang/srt/function_call/spark3_detector.py

新增 Spark3 工具调用解析器，解析 XML-KV 协议并处理流式边界，是 agent 场景的关键配套。

```
def _convert_value(value: str, param_type: str) -> Any:
    # 按工具声明的 JSON Schema 类型转换 XML 文本；
    # integer、number、boolean 等显式收窄，未声明或复合类型走 json.loads，失败则回退原文。
    if value.lower() == "null":
        return None
```

```
    normalized_type = param_type.lower()
    try:
        if normalized_type in {"string", "str", "text"}:
            return value
        if normalized_type in {"integer", "int"}:
            return int(value)
        if normalized_type in {"number", "float"}:
            number = float(value)
            return int(number) if number.is_integer() else number
        if normalized_type in {"boolean", "bool"}:
            normalized_value = value.strip().lower()
            if normalized_value not in {"true", "1", "false", "0"}:
                raise ValueError(f"invalid boolean: {value}")
            return normalized_value in {"true", "1"}
        return json.loads(value)
    except (TypeError, ValueError, json.JSONDecodeError):
        try:
            return json.loads(value)
        except (TypeError, ValueError, json.JSONDecodeError):
            return value
```

```
def _parse_tool_call_xml(tool_xml: str, tools: list[Tool]) -> _Spark3ToolCall | None:
    # 仅接受完整包裹的 <tool_call>...</tool_call> 块；
    # 函数名取块内第一个 <arg_key> 之前的文本，参数对按正则全部取出。
    if not tool_xml.startswith(TOOL_CALL_BEGIN) or not tool_xml.endswith(TOOL_CALL_END):
        return None
```

```
    body = tool_xml[len(TOOL_CALL_BEGIN) : -len(TOOL_CALL_END)]
    first_arg = body.find(ARG_KEY_BEGIN)
    function_name = (body if first_arg < 0 else body[:first_arg]).strip()
    if not function_name:
        return None
```

```
    arguments: dict[str, Any] = {}
    for match in ARG_PAIR_PATTERN.finditer(body):
        key, raw_value = match.group(1), match.group(2)
        if not key:
```

```

        continue
    arguments[key] = _convert_value(
        raw_value,
        _get_param_type(tools, function_name, key),
    )
return _Spark3ToolCall(name=function_name, arguments=arguments)

```

python/sglang/srt/configs/spark3.py

定义 Spark3Config，承载模型维度、layer_types 默认布局与两套 RoPE 参数，是模型可加载的前提。

```

from typing import Any, Optional

from transformers.configuration_utils import PretrainedConfig

class Spark3Config(PretrainedConfig):
    model_type = "spark3"
    architectures = ["Spark3ForCausalLM"]

    def __init__(
        self,
        hidden_size: int = 2048,
        intermediate_size: int = 6656,
        num_attention_heads: int = 8,
        num_key_value_heads: int = 2,
        num_hidden_layers: int = 28,
        head_dim: int = 256,
        headwise_attn_output_gate: bool = True,
        sliding_window: int = 512,
        vocab_size: int = 133120,
        rms_norm_eps: float = 1e-6,
        max_position_embeddings: int = 8192,
        rope_parameters: Optional[dict[str, Any]] = None,
        layer_types: list[str] = None,
        tie_word_embeddings: Optional[bool] = None,
        **kwargs,
    ) -> None:
        self.hidden_size = hidden_size
        self.intermediate_size = intermediate_size
        self.num_attention_heads = num_attention_heads
        self.num_key_value_heads = num_key_value_heads
        self.num_hidden_layers = num_hidden_layers
        self.head_dim = head_dim
        self.headwise_attn_output_gate = headwise_attn_output_gate
        self.sliding_window = sliding_window
        self.vocab_size = vocab_size
        self.rms_norm_eps = rms_norm_eps
        self.max_position_embeddings = max_position_embeddings

```

```

# 默认层级布局：每 4 层插入 1 个 full attention，其余为 sliding attention，
# 这是 Spark3 平衡长上下文成本与全局信息获取的关键设计。
if layer_types is not None:
    layer_types = layer_types[: self.num_hidden_layers]
else:
    layer_types = [
        "sliding_attention" if bool((i + 1) % 4) else "full_attention"
        for i in range(self.num_hidden_layers)
    ]
self.layer_types = layer_types

# 两套 RoPE 参数：full attention 走大 theta + 部分旋转，
# sliding attention 走小 theta + 全量旋转，保证局部窗口位置编码稳定。
if rope_parameters is not None:
    self.rope_parameters = rope_parameters
else:
    self.rope_parameters = {
        "full_attention": {
            "rope_theta": 5000000,
            "partial_rotary_factor": 0.25,
        },
        "sliding_attention": {
            "rope_theta": 10000,
            "partial_rotary_factor": 1.0,
        },
    }

super().__init__(**kwargs, tie_word_embeddings=tie_word_embeddings)

```

评论区精华

该 PR 没有产生实质性的技术讨论。唯一 review 来自 Fridge003，直接 APPROVED（评语 "\Nice\"). Issue 评论区主要是 CI 流程相关：whybeyoung 多次触发 [/tag-and-rerun-ci](#)，并提醒 "\lint first, then will be triggered\”，作者执行 pre-commit 修复后回复 "\done\”；dongjiang1989 也触发了一次 CI 重跑。整体呈现 "\新模型快速合并\" 的节奏，滑窗语义、head-wise 门控等设计点均未在公开评论中展开权衡讨论。

- 暂无高价值评论线程

风险与影响

- 风险：
 1. 模型侧零 E2E 测试：python/sglang/srt/models/spark3.py 新增 564 行，但没有加载、精度或长上下文测试；PR body 中的 MMLU-Pro 数据来自内部 benchmark，CI 无法复现，后续改动容易回归。
 2. 滑动窗口语义易错：_get_attention_sliding_window_size 依赖 HF 与 SGLang 对 inclusive/exclusive 的理解一致，一旦 checkpoint 层顺序或窗口配置不符，会产生静默的注意力截断错误。

3. 新机制组合风险: headwise_attn_output_gate、partial_rotary_factor 与量化、TP/PP 并存路径没有测试覆盖, 数值一致性问题难以被发现。
4. 全局解析器注册: Spark3Detector 进入 FunctionCallParser.ToolCallParserEnum 后, 相关进程都会加载该模块; 流式边界逻辑 (如 _partial_marker_suffix_length) 若出错会波及所有 spark parser 用户。
5. 长上下文承诺缺乏验证: PR body 声称原生 1M context, 但默认 max_position_embeddings 仅为 8192, 长文本依赖 RoPE 外推, 缺少实测数据。 - 影响: 用户侧: Spark3 1.7B/4B 用户可获得开箱即用的部署路径, 并能通过 --tool-call-parser spark 启用工具调用解析, 长上下文与 agent 场景是主要受益方向。系统侧: 改动集中在增量注册 (configs 导出、HF 注册表、parser 枚举), 对既有模型路径无侵入。团队侧: 本 PR 确立了 \"配置类 + 模型实现 + 工具解析器 + 单测\" 的新模型接入范式, 与 Nemotron 3.5 等近期模型支持一致, 但模型侧测试口径尚未统一, 后续需要补齐 E2E 精度覆盖。 - 风险标记: 新模型无 E2E 测试, 滑窗语义换算易错, 全局解析器注册, 1M 长上下文未实测

关联脉络

- PR #36186 [Model] Support Nemotron 3.5 Lightning speculative decoding: 同为新增模型架构支持 (dflash/dspark 配置与模型文件), 体现 SGLang 新模型接入的通用模式。
- PR #36284 [CI] Add Kimi-K3 MMMU-Pro accuracy coverage: 展示新模型接入后应配套的精度 CI 覆盖, 对照可见 Spark3 目前仅缺模型侧 E2E 验证。