

PR #45993 完整报告

vllm-project/vllm

[Model] Remove MiniMaxText01, MiniMaxVL01, MiniMaxForCausalLM

合并时间: 2026-06-22 15:20

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/45993>

执行摘要

- 一句话: 移除已淘汰的 MiniMax Text-01 和 VL-01 模型架构
- 推荐动作: 该 PR 值得精读, 展示了如何安全地淘汰旧模型架构: 通过 `_PREVIOUSLY_SUPPORTED_MODELS` 提供清晰错误提示替代静默失败, 同时保留共享组件避免影响其他模型。审查过程也体现了跨团队协作: 作者、MoE 专家、工具调用工程师共同确认删除范围。建议团队后续淘汰其他旧架构时参考此流程。

功能与动机

MiniMax Text-01 和 VL-01 已被 MiniMax M2 和 M3 全面取代, 继续维护旧架构会增加代码维护负担和混淆风险。本次清理移除了不再使用的模型定义、工具解析器与相关测试, 使代码库更精简。同时通过 `_PREVIOUSLY_SUPPORTED_MODELS` 机制保留了向后兼容的提示信息。

实现拆解

1. 删除核心模型代码: 移除 `vllm/model_executor/models/minimax_text_01.py` 和 `minimax_vl_01.py`, 包含所有模型类 (MiniMaxText01MLP、MiniMaxText01MoE、MiniMaxVL01MultiModalProjector 等)。
2. 删除 MiniMax M1 工具解析器: 根据审查者建议, 移除 `vllm/tool_parsers/minimax_tool_parser.py` 及其相关的工具调用模板 (`tool_chat_template_minimax_m1.jinja`) 和 Rust 快照测试。
3. 更新模型注册表: 在 `vllm/model_executor/models/registry.py` 中将四个旧架构添加到 `_PREVIOUSLY_SUPPORTED_MODELS`, 并移除其对应的模型字典条目。
4. 清理示例与测试: 从 `examples/generate/multimodal/vision_language_offline.py` 中删除 `run_minimax_vl_01` 函数; 移除 `tests/models/multimodal/processing/test_minimax_vl_01.py`、`tests/tool_parsers/test_minimax_tool_parser.py` 等测试文件; 在 `tests/models/multimodal/generation/test_common.py`、`tests/models/multimodal/generation/vlm_utils/model_utils.py` 中删除相关的测试条目。
5. 修复残留引用: 更新 `docs/contributing/model/basic.md` 中过时的内部链接, 修正 `test_attention_backends_selection.py` 中错误导入 `MiniMaxText01LinearAttention` 的位置。

关键文件:

- `vllm/model_executor/models/minimax_text_01.py` (模块 模型推理; 类别 source; 类型 deletion; 符号 `replace_weight_name`, `weight_loader_with_alias`, `wrapper`, `inner_func`) : 删除全部 1000 行代码, 是本次 PR 的核心删除文件。包含旧版 Text-01 模型的所有实现 (MLP、MoE、LinearAttention 等)。
- `vllm/model_executor/models/minimax_vl_01.py` (模块 模型推理; 类别 source; 类型 deletion; 符号 `MiniMaxVL01ImagePixelInputs`, `MiniMaxVL01ImageEmbeddingInputs`, `MiniMaxVL01MultiModalProjector`, `init`) : 删除 VL-01 视觉语言模型定义 (385 行), 包含多模态投影器、输入类型定义和处理器类。
- `vllm/tool_parsers/minimax_tool_parser.py` (模块 工具解析器; 类别 source; 类型 deletion; 符号 `MinimaxToolParser`, `init`, `preprocess_model_output`, `remove_tool_calls_from_think`) : 应审查者要求额外删除的 MiniMax M1 工具解析器 (852 行), 包含流式状态追踪、thinking tag 处理、JSON 清理等逻辑。
- `tests/tool_parsers/test_minimax_tool_parser.py` (模块 测试; 类别 test; 类型 deletion; 符号 `minimax_tokenizer`, `minimax_tool_parser`, `sample_tools`, `assert_tool_calls`) : 删除 MiniMax 工具解析器的配套测试 (1227 行), 包含 `parametrize` 测试用例。
- `vllm/model_executor/models/registry.py` (模块 模型注册表; 类别 source; 类型 data-contract) : 修改模型注册表: 移除旧架构的字典条目, 新增到 `_PREVIOUSLY_SUPPORTED_MODELS` (+4/-7)。
- `examples/generate/multimodal/vision_language_offline.py` (模块 示例; 类别 source; 类型 core-logic; 符号 `run_minimax_vl_01`) : 删除 `run_minimax_vl_01` 函数及其在路由字典中的注册。
- `tests/models/multimodal/processing/test_minimax_vl_01.py` (模块 测试; 类别 test; 类型 deletion; 符号 `test_processor_override`, `_validate_image_prompt_replacements_on_e`, `_test_image_prompt_replacements`, `test_processor_prompt_replacements_regression`) : 删除 VL-01 的多模态处理器测试文件 (113 行)。

关键符号: `replace_weight_name`, `weight_loader_with_alias`, `wrapper`, `inner_func`, `MiniMaxText01MLP.init`, `MiniMaxText01MLP.forward`, `MiniMaxText01MoE.init`, `MiniMaxVL01MultiModalProjector.init`, `MiniMaxVL01MultiModalProjector.forward`, `MinimaxToolParser.extract_tool_calls`, `MinimaxToolParser.preprocess_model_output`, `run_minimax_vl_01`

关键源码片段

`vllm/model_executor/models/minimax_text_01.py`

删除全部 1000 行代码, 是本次 PR 的核心删除文件。包含旧版 Text-01 模型的所有实现 (MLP、MoE、LinearAttention 等)。

```
# This is a representative snippet from the deleted file (base version).
# The class shows standard vLLM MLP pattern with parallel linear layers.
```

```
class MiniMaxText01MLP(nn.Module):
    """Standard MLP used by Text-01. 采用 MergedColumnParallelLinear + RowParallelLinear 结构"""
```

```

def __init__(
    self,
    hidden_size: int,
    intermediate_size: int,
    quant_config: QuantizationConfig | None = None,
    layer_idx: int = None,
    prefix: str = "mlp",
) -> None:
    super().__init__()
    self.layer_idx = layer_idx
    # 合并门控和上投影：两个输出通道
    self.gate_up_proj = MergedColumnParallelLinear(
        hidden_size,
        [intermediate_size] * 2,
        bias=False,
        quant_config=quant_config,
        prefix=f"{prefix}.gate_up_proj",
    )
    self.down_proj = RowParallelLinear(
        intermediate_size,
        hidden_size,
        bias=False,
        quant_config=quant_config,
        prefix=f"{prefix}.down_proj",
    )
    self.act_fn = SiluAndMul()

def forward(self, x: torch.Tensor) -> torch.Tensor:
    gate_up, _ = self.gate_up_proj(x)
    x = self.act_fn(gate_up)
    x, _ = self.down_proj(x)
    return x

```

vllm/model_executor/models/minimax_vl_01.py

删除 VL-01 视觉语言模型定义（385 行），包含多模态投影器、输入类型定义和处理器类。

多模态投影器：将视觉特征映射到文本空间

```

class MiniMaxVL01MultiModalProjector(nn.Module):
    """两层 MLP 投影器，与 LLaVA-NeXT 结构类似"""
    def __init__(
        self,
        vision_hidden_size: int,
        text_hidden_size: int,
        projector_hidden_act: str,
        multimodal_projector_bias: bool,
        quant_config: QuantizationConfig | None = None,
        prefix: str = "",
    ):
        super().__init__()

```

```

# 第一层：视觉隐层 -> 文本隐层（列并行）
self.linear_1 = ColumnParallelLinear(
    vision_hidden_size,
    text_hidden_size,
    bias=multimodal_projector_bias,
    quant_config=quant_config,
    prefix=f"{prefix}.linear_1",
)
self.act = get_act_fn(projector_hidden_act)
# 第二层：文本隐层 -> 文本隐层（行并行）
self.linear_2 = RowParallelLinear(
    text_hidden_size,
    text_hidden_size,
    bias=multimodal_projector_bias,
    quant_config=quant_config,
    prefix=f"{prefix}.linear_2",
)

def forward(self, image_features: torch.Tensor) -> torch.Tensor:
    hidden_states, _ = self.linear_1(image_features)
    hidden_states = self.act(hidden_states)
    hidden_states, _ = self.linear_2(hidden_states)
    return hidden_states

```

vllm/tool_parsers/minimax_tool_parser.py

应审查者要求额外删除的 MiniMax M1 工具解析器（852 行），包含流式状态追踪、thinking tag 处理、JSON 清理等逻辑。

MinimaxToolParser 核心构造逻辑

```

class MinimaxToolParser(ToolParser):
    """MiniMax M1 模型专用的工具解析器，处理 <tool_calls> 标签流"""
    def __init__(self, tokenizer: TokenizerLike, tools: list[Tool] | None = None):
        super().__init__(tokenizer, tools)
        # 流式状态：追踪当前工具进度
        self.streaming_state: dict[str, Any] = {
            "current_tool_index": -1,
            "tool_ids": [],
            "sent_tools": [],
        }
        # 工具调用的起始 / 结束标签
        self.tool_call_start_token = "<tool_calls>"
        self.tool_call_end_token = "</tool_calls>"
        self.tool_call_regex = re.compile(
            r"<tool_calls>(.*?)</tool_calls>|<tool_calls>(.*?)", re.DOTALL
        )
        # 尝试从 tokenizer 中获取 token ID，若失败则回退到字符串匹配
        self.tool_call_start_token_id = self.vocab.get(self.tool_call_start_token)
        self.tool_call_end_token_id = self.vocab.get(self.tool_call_end_token)
        if self.tool_call_start_token_id is None or self.tool_call_end_token_id is None:

```

```
logger.warning(  
    "Minimax Tool parser could not locate tool call start/end "  
    "tokens in the tokenizer. Falling back to string matching."  
)
```

评论区精华

审查者 sfeng33 要求额外移除 PR#20297 引入的 MiniMax M1 专用工具解析器，作者在第三个 commit 中落实。tdoublep 询问线性注意力 (minimax_linear_attn.py) 是否还被 M2 和 M3 使用，ZJY0516 确认仍被 Ling 2.5 模型使用，因此该共享模块未被删除。PR 触发了 pre-commit 和 merge 冲突的自动检查，均已解决。

- 删除 M1 工具解析器 (design): PR 作者在第三个 commit 中删除了 `vllm/tool_parsers/minimax_tool_parser.py` 及其相关测试和模板。
- 线性注意力是否仍被 M2/M3 使用 (question): ZJY0516 回应确认仍被 Ling 2.5 模型使用，因此共享模块被保留。

风险与影响

- 风险：主要风险在于遗漏对共享组件（如 `minimax_linear_attn.py`）的依赖检查，若其他模型依赖被删除的模块可能导致运行时错误。通过第二次 commit 修复了 `test_attention_backends_selection.py` 中的导入问题并更新了文档链接，降低了风险。工具解析器的删除不会影响 M2/M3 模型，因为它们的解析器是独立的。整体风险较低，因为所有被删除的架构均为已淘汰的旧版本。
- 影响：对用户的影响：使用 MiniMax M1 模型的用户无法再加载旧版检查点，需降级到 vLLM v0.23.0 或更早版本。对系统的影响：代码库大小减少约 3881 行，维护成本降低。对团队的影响：清理后模型注册表更清晰，减少了维护旧模型带来的混淆。没有对现有 M2/M3 模型的功能影响。
- 风险标记：核心模型删除，共享组件保留，工具解析器清理

关联脉络

- 暂无明显关联 PR