

PR #30150 完整报告

sgl-project/sglang

[diffusion][cache-dit] add dual-transformer Cache-DiT adapter specs

合并时间: 2026-07-07 23:10

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30150>

执行摘要

- 一句话: 为双 transformer Cache-DiT 添加声明式适配器规范
- 推荐动作: 该 PR 属于典型的数据驱动重构, 值得阅读以理解如何通过声明式配置替代条件分支, 提升代码的可扩展性和可读性。

功能与动机

避免将来添加双 transformer DiT 流水线时需要不断在 `enable_cache_on_dual_transformer` 中增加 if-else 分支, 通过数据驱动方式提升可扩展性。

实现拆解

1. 定义适配器规范类: 在 `cache_dit_integration.py` 中新增 `DualTransformerBlockAdapterSpec` 冻结数据类, 包含 `blocks_attr`、`blocks_name`、`forward_pattern` 等字段, 统一描述双 transformer 的 cache-dit 元数据。
2. 构建注册字典: 添加全局常量 `DUAL_TRANSFORMER_BLOCK_ADAPTER_SPECS`, 将 `wan2.2` 和 `ideogram4` 的元数据以模型名为键存储, 替换原有的 `_supported_dual_transformer_models` 列表。
3. 改造启用函数: 修改 `enable_cache_on_dual_transformer`, 通过 `adapter_spec = DUAL_TRANSFORMER_BLOCK_ADAPTER_SPECS.get(model_name)` 进行查找, 失败时抛异常, 后续逻辑使用 `adapter_spec` 字段替代散落在函数内的硬编码值。
4. 更新单元测试桩: 在 `test_cache_dit_integration.py` 中将 `cache_dit.ForwardPattern` 从 `SimpleNamespace` 改为自定义 `_FakeForwardPattern` 类, 并补充 `Pattern_2` 常量, 使类型注解 `List[ForwardPattern]` 能在 Python 3.10+ 正确工作。

关键文件:

- `python/sglang/multimodal_gen/runtime/cache/cache_dit_integration.py` (模块 DiT 集成; 类别 source; 类型 core-logic; 符号 `DualTransformerBlockAdapterSpec`, `DUAL_TRANSFORMER_BLOCK_ADAPTER_SPECS`): 核心变更文件: 引入 `DualTransformerBlockAdapterSpec` 类和注册字典, 重构 `enable_cache_on_dual_transformer` 的实现。
- `python/sglang/multimodal_gen/test/unit/test_cache_dit_integration.py` (模块 测试; 类别 test; 类型 test-coverage; 符号 `_FakeForwardPattern`): 测试配套文件: 更新 `ForwardPattern` 桩以支持 `Pattern_2` 和 `List[ForwardPattern]` 注解。

关键符号: enable_cache_on_dual_transformer

关键源码片段

[python/sglang/multimodal_gen/runtime/cache/cache_dit_integration.py](#)

核心变更文件: 引入 DualTransformerBlockAdapterSpec 类和注册字典, 重构 enable_cache_on_dual_transformer 的实现。

```
@dataclass(frozen=True)
class DualTransformerBlockAdapterSpec:
    """BlockAdapter metadata for dual-transformer DiT pipelines.
    This spec covers how cache-dit should find blocks and interpret each block's forward.
    """
    blocks_attr: tuple[str, str] # Attribute names to retrieve blocks from each transformer
    blocks_name: Optional[List[str]] # Optional explicit block names per transformer
    forward_pattern: List[ForwardPattern] # Forward pattern for each (e.g., Pattern_2, Pattern_3)
    check_forward_pattern: bool # Whether to validate forward signature
    check_num_outputs: bool # Whether to check number of outputs
    has_separate_cfg: bool # Whether each transformer has its own cache config

# Registry mapping model names to their adapter specs
DUAL_TRANSFORMER_BLOCK_ADAPTER_SPECS: dict[str, DualTransformerBlockAdapterSpec] =
{
    "wan2.2": DualTransformerBlockAdapterSpec(
        blocks_attr=("blocks", "blocks"),
        blocks_name=None,
        forward_pattern=[ForwardPattern.Pattern_2, ForwardPattern.Pattern_2],
        check_forward_pattern=True,
        check_num_outputs=False,
        has_separate_cfg=True,
    ),
    "ideogram4": DualTransformerBlockAdapterSpec(
        blocks_attr=("layers", "layers"),
        blocks_name=["layers", "layers"],
        forward_pattern=[ForwardPattern.Pattern_3, ForwardPattern.Pattern_3],
        check_forward_pattern=False,
        check_num_outputs=False,
        has_separate_cfg=False,
    ),
}
```

[python/sglang/multimodal_gen/test/unit/test_cache_dit_integration.py](#)

测试配套文件: 更新 ForwardPattern 桩以支持 Pattern_2 和 List[ForwardPattern] 注解。

```
class _FakeForwardPattern:
    # A class (not SimpleNamespace) so it is a valid type in
    # annotations like List[ForwardPattern], matching the real Enum.
```

```
Pattern_2 = "Pattern_2"
Pattern_3 = "Pattern_3"
```

```
def _install_cache_dit_stub():
    # ... other stub setup ...
    cache_dit.ForwardPattern = _FakeForwardPattern # Replaces SimpleNamespace
    # Now List[ForwardPattern] works during import / type checking
```

评论区精华

gemini-code-assist[bot] 指出新数据类字段使用了 PEP 604 联合类型“`str | None`”，可能在不支持该语法的 Python 版本上造成运行时错误，建议改用 `Optional[List[str]]`。作者 Jzz1943 采纳建议并更新了类型注解，同时指出主要动机是更精确的 `transformerblocks_name` 类型。

- 类型注解兼容性 (correctness): 作者 Jzz1943 采纳建议，将 `blocks_name` 改为 `Optional[List[str]]`，`forward_pattern` 改为 `List[ForwardPattern]`。

风险与影响

- 风险：本次重构仅移动元数据结构，不改变运行时行为，回归风险极低。唯一的兼容性风险（Python <3.10 的联合类型语法）已在 review 中修复，且测试通过。
- 影响：对用户透明，无性能影响。对开发团队而言，新增双 transformer 模型时只需向 `DUAL_TRANSFORMER_BLOCK_ADAPTER_SPECS` 添加一条记录即可，无需修改函数体，降低了维护成本。
- 风险标记：低风险重构，类型兼容性修复

关联脉络

- 暂无明显关联 PR