

PR #30040 完整报告

sgl-project/sglang

[diffusion] feat: add LingBot realtime prompt, KV window, and lazy VAE controls

合并时间: 2026-07-05 11:11

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30040>

执行摘要

- 一句话: LingBot 实时新增复合输入、KV 窗口和延迟 VAE
- 推荐动作: 值得精读。交互式 KV 窗口的设计模式 (重置默认值 + 按需调整) 和复合输入原子性校验可复用。关注 `causal_attention_cache` 的 `recent_window_tokens` 参数, 它是通用层的变化, 可能被其他模型使用。

功能与动机

来自 PR body: "Add LingBot realtime support for composite prompt and camera-action inputs in a single event." 此外, 为了在实时视频生成中减少 prompt 更新导致的 cross-attention cache 全量清除开销、改善 camera-motion 下的运动连续性、以及降低 VAE 编码计算负担。

实现拆解

1. 复合输入事件解析与原子性更新 (`lingbot_world_realtime_adapter.py`): 新增 `_ingest_composite_input` 方法, 先验证所有 `input_types` 再依次调用 `_ingest_camera_actions` 和 `_ingest_prompt`, 确保部分失败时不改变状态。
2. 交互式 KV 窗口控制 (`lingbot_world_causal_denoising.py`): 新增 `_apply_causal_cache_overrides` 重写父类方法, 先重置 `cache` 配置为模型默认值, 再调用父类 `override`, 最后通过 `_sync_interactive_kv_cache_window` 根据 camera-motion 动态调整 `sliding_window_num_frames` 和 `sink_size`。 `_chunk_has_camera_motion` 和 `_uses_interactive_kv_window` 判断是否需要启用。
3. 动态 `recent_window_tokens` 支持 (`causal_attention_cache.py`): `update_and_get_attention_kv` 新增 `recent_window_tokens` 参数, 提取 `_visible_attention_kv` 方法返回 `sink tokens` + 动态窗口的 KV 切片, 为交互式窗口提供底层实现。
4. Prompt 更新标记与 cross-attention 重置: `adapter` 在 `ingest prompt` 时设置 `LINGBOT_PROMPT_UPDATED_CONDITION` 条件, `denoising stage` 据此决定是否重置 cross-attention cache。
5. 延迟 VAE 编码 (`lingbot_world.py`): `preprocess_vae_encode` 根据 `SGLANG_LINGBOT_LAZY_VAE_ENCODE_BLACK_FRAMES` 环境变量或配置, 只编码首帧和指定数量的填充帧, 后续用最后一帧的 `latent` 重复填充。

6. 环境变量与配置项：新增 `interactive_kv_window_enable`、`interactive_kv_still_window`、`interactive_kv_moving_window`、`lazy_vae_encode_black_frames` 等字段，默认关闭 / 零。

关键文件：

- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/model_specific_stages/lingbot_world/lingbot_world_causal_denoising.py`（模块 去噪阶段；类别 `source`；类型 `data-contract`；符号 `_chunk_has_camera_motion`，`_uses_interactive_kv_window`，`_interactive_kv_window_enabled`，`_apply_causal_cache_overrides`）：核心业务逻辑：交互式 KV 窗口控制、prompt 更新检测、cache override 重置和同步
- `python/sglang/multimodal_gen/runtime/entrypoints/openai/realtime/adapters/lingbot_world_realtime_adapter.py`（模块 实时适配器；类别 `source`；类型 `dependency-wiring`；符号 `receive_camera_control_event_payload`，`parse_camera_control_event_payload`，`receive_parsed_camera_control_event_payload`，`_ingest_camera_actions`）：复合输入事件解析、原子性校验和分发，prompt 更新标记传递
- `python/sglang/multimodal_gen/runtime/layers/kvcache/causal_attention_cache.py`（模块 KV 缓存；类别 `source`；类型 `core-logic`；符号 `_visible_attention_kv`）：通用因果 KV 缓存新增 `recent_window_tokens` 动态窗口选择，影响所有使用该缓存的模型
- `python/sglang/multimodal_gen/configs/pipeline_configs/lingbot_world.py`（模块 配置；类别 `source`；类型 `core-logic`；符号 `preprocess_vae_encode`）：配置类新增 `interactive_kv_window` 和 `lazy_vae_encode` 字段，并实现延迟 VAE 编码逻辑
- `python/sglang/multimodal_gen/test/unit/realtime/test_lingbot_causal_denoising.py`（模块 测试；类别 `test`；类型 `test-coverage`；符号 `test_lingbot_realtime_attention_cache_samples_sink_and_recent_window`，`test_lingbot_interactive_kv_window_config_default_disabled`，`test_lingbot_lazy_vae_encode_black_frames_env`，`test_lingbot_interactive_kv_window_samples_base_moving_and_still`）：单元测试覆盖交互式 KV 窗口、动态窗口采样和延迟 VAE 环境变量
- `python/sglang/multimodal_gen/test/unit/realtime/test_realtime_runtime.py`（模块 测试；类别 `test`；类型 `test-coverage`；符号 `test_lingbot_realtime_adapter_ingests_composite_input_event`，`test_lingbot_realtime_adapter_rejects_composite_input_atomically`，`test_lingbot_realtime_prompt_event_marks_crossattn_reset`）：集成测试验证复合输入正常流程、原子性拒绝和 prompt 更新标记

关键符号：`_chunk_has_camera_motion`，`_uses_interactive_kv_window`，`_interactive_kv_window_enabled`，`_apply_causal_cache_overrides`，`_reset_causal_cache_config_defaults`，`_sync_interactive_kv_cache_window`，`_effective_interactive_kv_cache_num_frames`，`_build_realtime_causal_cache_policy`，`receive_camera_control_event_payload`，`parse_camera_control_event_payload`，`receive_parsed_camera_control_event_payload`，`_ingest_camera_actions`，`_ingest_prompt`，`_validate_prompt_payload`，`_ingest_composite_input`，`_parse_composite_input_item`，`_visible_attention_kv`，`preprocess_vae_encode`

关键源码片段

python/sglang/multimodal_gen/runtime/layers/kvcache/causal_attention_cache.py

通用因果 KV 缓存新增 recent_window_tokens 动态窗口选择，影响所有使用该缓存的模型

```
def _visible_attention_kv(
    self,
    *,
    local_start_index: int,
    updated_local_end: int,
    attn_start_index: int,
    recent_window_tokens: int | None,
    cache_head_slice: slice | None = None,
) -> tuple[torch.Tensor, torch.Tensor]:
    """返回当前 attention 调用可见的 KV 切片。

    * 当 ``recent_window_tokens`` 为 ``None`` 时，返回标准滑动窗口
      ``[attn_start_index, updated_local_end)``;
    * 当启用 recent-window 选择时，返回 sink tokens 加上当前 chunk
      以及最多 recent_window_tokens 个历史帧的 KV:
      ``[0, sink_end) + [recent_start, updated_local_end)``;
      其中 ``recent_start = max(sink_end, local_start_index - recent_window_tokens)``。
    * 传入 ``0`` 则只保留 sink tokens 加当前 chunk。
    * 负值视为 ``None``（全窗口）。
    """
    if recent_window_tokens is None:
        # 标准滑动窗口行为：无动态截断
        visible_k = self.k[:, attn_start_index:updated_local_end]
        visible_v = self.v[:, attn_start_index:updated_local_end]
    else:
        # 动态窗口：保持 sink tokens 和最近的 recent_window_tokens
        sink_end = min(self.sink_tokens, updated_local_end)
        # 计算 recent 部分的起始位置，不能早于 sink_end
        recent_start = max(sink_end, local_start_index - recent_window_tokens)
        # 拼接 sink 部分和 recent 部分
        visible_k = torch.cat(
            [self.k[:, :sink_end], self.k[:, recent_start:updated_local_end]], dim=1
        )
        visible_v = torch.cat(
            [self.v[:, :sink_end], self.v[:, recent_start:updated_local_end]], dim=1
        )
    if cache_head_slice is not None:
        visible_k = visible_k[:, :, cache_head_slice, :]
        visible_v = visible_v[:, :, cache_head_slice, :]
    return visible_k, visible_v
```

评论区精华

1. 状态污染风险: gemini-code-assist[bot] 指出共享 stage 实例的 self.sink_size 和 self.sliding_window_num_frames 在请求间需重置, 否则状态污染。作者添加 _reset_causal_cache_config_defaults() 在 _apply_causal_cache_overrides 开头恢复默认值。
 2. 复合输入原子性: gemini-code-assist[bot] 建议先验证所有输入类型再更新状态, 避免部分失败留下脏数据。作者重写 _ingest_composite_input 为两阶段: 先解析验证所有 input_types, 再统一更新状态。
 3. 常量文件位置: mickqian 建议将 LingBot 常量从通用 realtime 目录移到模型专属目录。作者将 constants.py 移至 model_specific_stages/lingbot_world/ 下。
 4. 文档完善: mickqian 两次要求为 _visible_attention_kv 方法和 update_and_get_attention_kv 的 recent_window_tokens 参数添加文档。作者均已完成。
- 状态污染风险: 共享 stage 属性需重置 (correctness): 作者添加 _reset_causal_cache_config_defaults() 在 _apply_causal_cache_overrides 开头恢复默认值, 确保请求隔离。
 - 复合输入原子性: 部分失败导致脏状态 (correctness): 作者重写 _ingest_composite_input 先解析验证所有 input_types, 再统一更新状态, 保证原子性。
 - 常量文件位置: 迁移到模型专属目录 (design): 作者将 constants.py 移至 model_specific_stages/lingbot_world/constants.py。
 - 文档完善: _visible_attention_kv 和 recent_window_tokens 参数 (documentation): 作者添加了完整的 docstring 和注释, 解释 None/0/ 正值的含义及返回的 token 范围。

风险与影响

- 风险: 状态重置有效性: 虽然已增加 _reset_causal_cache_config_defaults(), 但若模型 arch_config 中缺少相关属性, 重置可能失败, 导致配置残留。并发安全: real time 路径假设请求串行处理, 但若引入并行 pipeline, 共享 stage 属性仍可能有竞态。性能分支: recent_window_tokens 为 None 时走原路径, 开销为零; 非 None 时增加一次 token 拼接和判断, 影响较小。测试覆盖: 新增单元测试覆盖主要逻辑, 但缺少集成端到端测试。
- 影响: 用户影响: 使用 LingBot-World 实时服务的用户可以传入 composite_input 事件并在一次请求中同时更新 prompt 和 camera-actions; 可开启交互式 KV 窗口获得更流畅的运动变化; 延迟 VAE 编码减少初始化延迟。系统影响: 新增环境变量 (SGLANG_LINGBOT_ENABLE_INTERACTIVE_KV_WINDOW、SGLANG_LINGBOT_LAZY_VAE_ENCODE_BLACK_FRAMES), 默认关闭, 不影响现有行为。团队影响: 需维护新的配置项和条件分支, 但代码有测试保护。
- 风险标记: 核心缓存层变更, 状态管理已修复, 配置项默认关闭

关联脉络

- 暂无明显关联 PR