

PR #36726 完整报告

sgl-project/sglang

[Diffusion] Fix the five unit tests failing on main

合并时间: 2026-08-28 12:18

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36726>

执行摘要

- 一句话: 修复 diffusion 五个单元测试, 含两个 realtime 相机运行时 bug
- 推荐动作: 值得精读。重点看 ControlStateQueue 的“无信号 vs 保持电平”状态建模 (`_received_any + mark_received`), 以及 CI glob 遗漏导致测试静默失效的根因修复方式; 对 diffusion/realtime 模块的开发者是很好的参考。insight 主要来自语义设计与测试工程实践, 而非算法创新。

功能与动机

PR body 明确指出: `Five tests under python/sglang/multimodal_gen/test/unit fail on current main. They never ran in CUDA CI — the nested unit directories (realtime/, sana_wm/) sit outside the CI file glob, and one expectation depended on the host GPU — so the failures accumulated silently.` 其中两个失败是真实运行时 bug:

`ControlStateQueue.sample_chunk` 在从未收到控制时仍合成保持态转换, 导致新会话把默认相机状态误报为活动信号; 缓存 streaming 相机分支跳过了 dense 分支的 RMS downscale, 破坏单 chunk 归约到 dense 计算的契约。

实现拆解

按提交顺序拆解为 4 步:

1. 修复控制信号语义 (提交 1): `runtime/realtime/control_signals.py` 的 `ControlStateQueue` 新增 `_received_any` 标志——`push()` 首次调用即置位, `sample_chunk()` 在无 pending 转换且从未收到控制时返回 `None` (不再合成默认状态), `clear()` 重置标志; 新增 `mark_received()` 用于“无 transition 但需保持电平”的场景。配套 `states/camera_control.py` 的 `receive_camera_action_script()` 在 `clear()` 后调用 `mark_received()`, 保证相机动作脚本本身算作信号, 脚本排空后保持结束状态而非回到无信号。`test/unit/realtime/test_realtime_runtime.py` 更新两处过期期望: `fresh` 会话 `sample_camera_actions(3)` 应为 `None`; `latent-prep stub` 移除多余的 `arch_config` 嵌套。
2. 恢复缓存相机分支的 RMS downscale (提交 2): `runtime/models/dits/sana_wm_components.py` 的 `_cam_branch_cached` 与 `_cam_branch_softmax_cached` 在 UCPE 投影后, 对 `q/k/v` 调用 `_downscale_to_reference_rms` 缩回 pre-UCPE per-token RMS, 与 dense 分支 `_cam_branch/_cam_branch_softmax` 数值对齐; 单 chunk 无携带状态时精确退化为 dense 计算, 由 `test_cam_gdn_cached_single_chunk_reduces_to_dense` 校验。dense 路径完全不动。

3. 修复过期测试 pin (提交 3) : test/unit/realtime/test_realtime_webui.py 将资源版本从 realtime-sr-v38/rgb-worker-v6 更新为 realtime-record-v49/rgb-worker-v10, 同步 UI 字符串断言 (如 setStatus("Receiving", "live")、decodeQueue.push() 并新增读取 playback_controller.js; test/unit/test_consistency_metrics.py 通过 monkeypatch 固定 SGLANG_DIFFUSION_CONSISTENCY_PLATFORM=h100, 消除对宿主 GPU 的依赖。
4. 扩大 CI 发现范围 (提交 4) : test/server/gpu_cases.py 的 _discover_unit_tests() 在非 AMD 平台直接返回 ["../unit"], 让 pytest 递归发现 realtime/、sana_wm/、progressive_resolution/ 等嵌套目录全部测试; AMD/ROCm 保留 vetted 列表。这从根因上杜绝“测试静默漏跑”, 新嵌套测试无需注册即可被 CUDA CI 覆盖。

关键文件:

- python/sglang/multimodal_gen/runtime/realtime/control_signals.py (模块 控制信号; 类别 source; 类型 core-logic; 符号 ControlStateQueue, push, sample_chunk, mark_received) : 核心运行时 bug 修复: ControlStateQueue 新增 _received_any 标志与 mark_received(), 规定“从未收到控制时采样返回 None、收到后保持电平”的语义, 消除 fresh 会话误报默认相机状态的问题。
- python/sglang/multimodal_gen/runtime/models/dits/sana_wm_components.py (模块 模型组件; 类别 source; 类型 data-contract; 符号 _cam_branch_cached, _cam_branch_softmax_cached, _downscale_to_reference_rms) : 模型 forward 数值契约修复: 缓存 streaming 相机分支恢复与 dense 分支相同的 per-token RMS downscale, 保证单 chunk 无携带状态时精确退化为 dense 计算。
- python/sglang/multimodal_gen/test/server/gpu_cases.py (模块 测试编排; 类别 test; 类型 test-coverage; 符号 _discover_unit_tests, _AMD_READY_NESTED_UNIT_TESTS) : CI 根因修复: _discover_unit_tests 在 CUDA lane 改为递归运行整棵 unit 树, 让 realtime/、sana_wm/ 等嵌套测试进入 CI, 杜绝再次静默漏跑。
- python/sglang/multimodal_gen/runtime/realtime/states/camera_control.py (模块 控制信号; 类别 source; 类型 core-logic; 符号 receive_camera_action_script) : receive_camera_action_script 在 clear() 后调用 mark_received(), 把脚本本身视为信号, 脚本排空后保持结束状态而非回到无信号。
- python/sglang/multimodal_gen/test/unit/realtime/test_realtime_webui.py (模块 界面测试; 类别 test; 类型 test-coverage; 符号 test_realtime_webui_presets_do_not_emit_camera_scripts) : webui 测试 pin 更新: 资源版本与 UI 字符串从 realtime-sr-v38 更新到 realtime-record-v49, 并新增 playback_controller.js 的断言。
- python/sglang/multimodal_gen/test/unit/realtime/test_realtime_runtime.py (模块 运行时测试; 类别 test; 类型 test-coverage; 符号 test_lingbot_realtime_state_uses_control_script_and_prompt_queues, test_realtime_chunk_latent_preparation_uses_chunk_spec) : 修复两处过期期望: fresh 会话采样应为 None 而非空列表; latent-prep stub 移除多余的 arch_config 嵌套。
- python/sglang/multimodal_gen/test/unit/test_consistency_metrics.py (模块 一致性测试; 类别 test; 类型 test-coverage) : 通过 monkeypatch 固定 SGLANG_DIFFUSION_CONSISTENCY_PLATFORM=h100, 消除测试对宿主 GPU 的依赖, 使候选路径解析逻辑在任何机器上可复现。

关键符号: ControlStateQueue.push, ControlStateQueue.sample_chunk,
ControlStateQueue.mark_received, ControlStateQueue.clear,
receive_camera_action_script, _cam_branch_cached, _cam_branch_softmax_cached,
_discover_unit_tests

关键源码片段

python/sglang/multimodal_gen/runtime/realtime/control_signals.py

核心运行时 bug 修复: ControlStateQueue 新增 _received_any 标志与 mark_received(), 规定“从未收到控制时采样返回 None、收到后保持电平”的语义, 消除 fresh 会话误报默认相机状态的问题。

```
class ControlStateQueue:
    """State-mode sampler for level-triggered realtime controls."""

    def __init__(self, *, default_item, min_pulse_items=1, max_transitions=512) -> None:
        self.default_item = default_item
        self.min_pulse_items = min_pulse_items
        self._pending: deque[ControlStateTransition] = deque(maxlen=max_transitions)
        self._current_item = default_item
        self._current_seq_id: int | None = None
        self._latest_sampled_seq_id: int | None = None
        # 从未收到 transition 的队列没有可保持的状态:
        # 采样时返回 None, 调用方整体省略该控制;
        # 收到第一个 transition 之后电平保持, default 值也视为保持态。
        self._received_any = False

    def clear(self) -> None:
        self._pending.clear()
        self._current_item = self.default_item
        self._current_seq_id = None
        self._latest_sampled_seq_id = None
        self._received_any = False

    def push(self, transition: ControlStateTransition) -> None:
        self._pending.append(transition)
        self._received_any = True

    def mark_received(self) -> None:
        """无 transition 也武装保持: 替换脚本本身就是信号,
        因此脚本排空后继续采样其结束状态作为保持电平。"""
        self._received_any = True

    def sample_chunk(self, chunk_size: int) -> list[Any] | None:
        if chunk_size <= 0:
            return None

        transitions = self._drain_pending()
```

```

if not transitions:
    # 关键修复：从未收到控制时返回 None，而不是把默认状态当作活动信号
    if not self._received_any:
        return None
    self._latest_sampled_seq_id = self._current_seq_id
    return [self._copy_item(self._current_item) for _ in range(chunk_size)]

pulse = self._latest_non_default_transition(transitions)
final = transitions[-1]
self._current_item = final.payload
self._current_seq_id = final.seq_id

if pulse is not None and pulse.payload != final.payload:
    # 短暂脉冲：先填充 min_pulse_items 个脉冲值再切换为最终电平
    pulse_items = min(self.min_pulse_items, chunk_size)
    chunk = [self._copy_item(pulse.payload) for _ in range(pulse_items)]
    chunk.extend(
        self._copy_item(final.payload) for _ in range(chunk_size - pulse_items)
    )
    self._latest_sampled_seq_id = (
        final.seq_id if len(chunk) > pulse_items else pulse.seq_id
    )
    return chunk

self._latest_sampled_seq_id = final.seq_id
return [self._copy_item(final.payload) for _ in range(chunk_size)]

```

python/sglang/multimodal_gen/runtime/models/dits/sana_wm_components.py

模型 forward 数值契约修复：缓存 streaming 相机分支恢复与 dense 分支相同的 per-token RMS downscale，保证单 chunk 无携带状态时精确退化为 dense 计算。

```

# _cam_branch_cached 内部：缓存 streaming 分支与 dense 分支保持同一数值契约
q_pre_dn = q_bhnd.permute(0, 1, 3, 2)
q_dn = q_proj.permute(0, 1, 3, 2)
k_pre_dn = k_bhnd.permute(0, 1, 3, 2)
k_dn = k_proj.permute(0, 1, 3, 2)
v_pre_dn = v_bhnd.permute(0, 1, 3, 2)
v_dn = v_proj.permute(0, 1, 3, 2)

# 与 _cam_branch 相同的 per-token RMS downscale:
# 单 chunk 无携带状态时精确退化为 dense scan 的计算路径
q_dn = _downscale_to_reference_rms(q_pre_dn, q_dn)
k_dn = _downscale_to_reference_rms(k_pre_dn, k_dn)
v_dn = _downscale_to_reference_rms(v_pre_dn, v_dn)

# 膨胀系数基于缩放前后的 K 范数比值计算，修正 beta
pre_ucpe_k_norm = torch.linalg.vector_norm(
    k_pre_dn.float(), dim=2, keepdim=True
)

```

```

).clamp_min(1e-6)
post_ucpe_k_norm = torch.linalg.vector_norm(
    k_dn.float(), dim=2, keepdim=True
).clamp_min(1e-6)
inflation_sq = (post_ucpe_k_norm / pre_ucpe_k_norm) ** 2
frame_inflation_sq = inflation_sq.view(B, self.heads, T, S).mean(dim=-1)
if beta.ndim == 3:
    beta = beta / frame_inflation_sq.clamp_min(1.0)
elif beta.ndim == 4:
    beta = beta / frame_inflation_sq.unsqueeze(-1).clamp_min(1.0)

# 无状态 Triton scan 的缓存调用, 携带 camera K 状态
out, cam_state = _single_path_delta_scan_cached(
    q_dn.float(),
    k_dn.float(),
    v_dn.float(),
    beta.float(),
    decay.float(),
    init_state_kv=kv_cache[_SLOT_CAM_K],
)

```

[python/sglang/multimodal_gen/test/server/gpu_cases.py](#)

CI 根因修复: `_discover_unit_tests` 在 CUDA lane 改为递归运行整棵 unit 树, 让 `realtime/`、`sana_wm/` 等嵌套测试进入 CI, 杜绝再次静默漏跑。

```

def _discover_unit_tests() -> list[str]:
    unit_dir = Path(__file__).resolve().parent.parent / "unit"
    if not unit_dir.is_dir():
        return []
    if not current_platform.is_hip():
        # pytest 递归进入目录: 全部单元测试都会运行 (含嵌套子目录),
        # 新文件无需注册即可被 CI 发现, 防止再次出现测试静默漏跑
        return ["../unit"]
    # AMD/ROCm 保留 vetted 集合: 仅跑已验证通过的扁平文件与嵌套测试
    flat = [f"../unit/{f.name}" for f in unit_dir.glob("test_*.py") if f.is_file()]
    nested = [
        f"../unit/{rel}"
        for rel in _AMD_READY_NESTED_UNIT_TESTS
        if (unit_dir / rel).is_file()
    ]
    return sorted(flat + nested)

```

评论区精华

PR 级评论: 审核者 [AgainstEntropy](#) 在查看修复过程后提出 [We can expand the searching paths to include these missing unit tests](#), 这正是提交 4 的实现方式——CUDA lane 改为递归运行整棵 unit 树, AMD lane 维持 vetted 集合; 该建议落地后审核者 APPROVED。行内评论: [control_signals.py](#) 第 418 行处 [duplication here](#), 指 `push()` 与新增的

`mark_received()` 都执行 `self._received_any = True`, 属轻微重复; 无后续回复, PR 按现状合并, 单行标志赋值的重复可接受。

- CI 搜索路径应包含嵌套单元测试目录 (design): 提交 4 实现该建议: CUDA lane 的 `_discover_unit_tests` 改为返回 `["../unit"]` 由 `pytest` 递归发现, AMD/ROCm 保留 `vetted` 集合; 随后审核者 APPROVED。
- `push` 与 `mark_received` 重复设置 `_received_any` (style): 无后续回复, PR 按现状合并; 重复仅为单行标志赋值, 可接受的轻微冗余。

风险与影响

- 风险:
 1. 控制语义变更: `sample_chunk()` 现在对从未收到控制的队列返回 `None` 而非默认项, 所有调用方必须能处理 `None`; 若存在测试未覆盖的调用点 (如脚本与状态队列组合路径), 可能引入遗漏。
 2. 模型数值路径变更: `sana_wm_components.py` 的缓存 `streaming` 分支数值发生变化, 虽然是对齐 `dense` 路径, 但 `streaming` 输出、缓存状态与 `beta` 修正的数值均有差异, 依赖旧输出的场景需回归验证; PR 用单 `chunk` 归约测试收紧约束, 但多 `chunk` 携带状态场景仍依赖既有测试。
 3. CI 覆盖扩大: CUDA lane 从扁平 `glob` 扩展为递归整树, 运行时间增长, 且可能首次暴露其他此前静默失败的嵌套测试 (这是有意的, 但短期可能引入 CI 不稳定)。
 4. 测试与前端强耦合: `test_realtime_webui.py` 大量断言 `webui` 资源版本与 UI 字符串, 前端迭代必须同步更新测试, 存在维护摩擦。
 - 影响: 用户侧: `realtime` 视频生成 `fresh` 会话不再把默认相机状态误报为活动信号; 流式缓存相机路径与 `dense` 数值对齐, 输出一致性提升。系统侧: CUDA CI 对 `diffusion` 单元测试的覆盖面从扁平 `glob` 扩大为整棵 `unit` 树, 质量门禁更真实。团队侧: `multimodal_gen` 测试基线从“偶然全绿”变为“真正全绿”, 降低后续改动的回归误判; AMD/ROCm lane 不受影响, 仍走 `vetted` 列表。
 - 风险标记: 控制语义变更, 模型数值路径变更, CI 覆盖范围扩大, 测试与前端强耦合

关联脉络

- PR #36658 [`multimodal_gen`] fix: make `tail_attn_meta` CUDA-graph capturable: 同属 `multimodal_gen/diffusion` 模块的测试与运行时修复线, 且都涉及嵌套单元测试目录 (`realtime/`) 在 CI 中的覆盖问题。