

PR #34242 完整报告

sgl-project/sglang

[diffusion] Warn when BCG disables Cache-DiT

合并时间: 2026-08-14 16:45

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34242>

执行摘要

- 一句话: BCG 下 Cache-DiT 静默禁用, 现补一次性警告
- 推荐动作: 值得快速浏览而非精读: 改动虽小, 但“一次性告警 + 请求级路径覆盖 + 测试对全局去重函数做 `cache_clear` 隔离”的设计可作为同类静默失效问题的修复模板。若后续要扩展 Cache-DiT 与 BCG 的兼容性, 本 PR 的告警位置是天然入口。

功能与动机

Issue #34177 明确指出: 同时启用 `--enable-breakable-cuda-graph` 和 `SGLANG_CACHE_DIT_ENABLED=1` 时, Cache-DiT 既不生效、也不报错、也不警告, “唯一症状是 1.00x 加速”, 容易被用户误读为“Cache-DiT 对该模型无效”。issue 还强调仅启动时检查不够, 因为 MiniMax-H3 会在 `quality="high"` 批次动态挂载 Cache-DiT, 告警应覆盖请求级路径, 并且“每进程一次即可, 不应逐请求记录”。

实现拆解

1. 定位早退分支: `python/sglang/multimodal_gen/runtime/pipelines_core/stages/denoising.py` 中 `DenoisingStage._maybe_enable_cache_dit` 开头即检查 `server_args.enable_breakable_cuda_graph`, 命中则直接 `return`, 这是 Cache-DiT 被静默禁用的根因位置。
2. 注入告警: 在 `return` 之前新增 `if self._cache_dit_requested(): logger.warning_once(...)`。`_cache_dit_requested()` 统一表达“环境变量或请求级显式请求”, 因此启动路径和 MiniMax-H3 动态挂载路径共享同一判定; `logger.warning_once` 基于 `logging_utils._print_warning_once` 做进程级去重, 未请求时保持原有静默行为。
3. 测试配套 (两个文件、三个用例): `test_diffusion_bcg_padding.py` 新增 `test_bcg_warns_when_cache_dit_is_requested` (连续两次调用断言 `logger.warning` 只调用一次且 `stacklevel=2`, 测试前后 `_print_warning_once.cache_clear()` 重置全局去重缓存) 和 `test_bcg_does_not_warn_when_cache_dit_is_not_requested` (`patch` 返回 `False`, 断言 `warning_once` 不被调用); `test_minimax_h3_admission.py` 新增 `test_high_quality_request_warns_when_bcg_suppresses_cache_dit`, 构造 `quality="high"` 且 `_explicit_fields={"quality"}` 的批次验证请求级路径。
4. 配置与部署配套: 无配置文件、schema 或文档改动, 符合 PR body 中 `diagnostic-only change` 的定位。CI Extra 存在一次失败 (Run #31369399616), 材料未给出失败原因, 需以 CI 日志为准。

关键文件：

- python/sglang/multimodal_gen/runtime/pipelines_core/stages/denoising.py（模块 去噪管线；类别 source；类型 core-logic；符号 `_maybe_enable_cache_dit`, `_cache_dit_requested`）：核心逻辑变更处：在 `_maybe_enable_cache_dit` 的 BCG 早退分支中新增 `_cache_dit_requested()` 判断并发出进程级一次性警告，是本次修复的关键入口。
- python/sglang/multimodal_gen/test/unit/test_diffusion_bcg_padding.py（模块 图形捕获；类别 test；类型 test-coverage；符号 `test_bcg_warns_when_cache_dit_is_requested`, `test_bcg_does_not_warn_when_cache_dit_is_not_requested`）：新增两个单元测试，验证请求了 Cache-DiT 且 BCG 启用时只告警一次、未请求时不告警，并验证 `stacklevel=2` 与进程级去重语义。
- python/sglang/multimodal_gen/test/unit/test_minimax_h3_admission.py（模块 请求准入；类别 test；类型 test-coverage；符号 `test_high_quality_request_warns_when_bcg_suppresses_cache_dit`）：覆盖 MiniMax-H3 请求级动态挂载路径：`quality="high"` 批次在 BCG 抑制下同样触发告警，补全 issue 要求的请求级场景。

关键符号： `_maybe_enable_cache_dit`, `_cache_dit_requested`, `_print_warning_once`

关键源码片段

python/sglang/multimodal_gen/runtime/pipelines_core/stages/denoising.py

核心逻辑变更处：在 `_maybe_enable_cache_dit` 的 BCG 早退分支中新增 `_cache_dit_requested()` 判断并发出进程级一次性警告，是本次修复的关键入口。

```
# python/sglang/multimodal_gen/runtime/pipelines_core/stages/denoising.py
# 每个请求进入去噪流程时都会调用本方法，负责挂载或刷新 Cache-DiT。
# 当启用 breakable CUDA graph 时，Cache-DiT 的 step-skipping 控制流
# 不能被打进被捕获的 CUDA 图，因此原本在这里直接提前返回（静默禁用）。
# 本 PR 在返回前补上“仅当 Cache-DiT 被请求时”的一次性告警。
def _maybe_enable_cache_dit(
    self, num_inference_steps: int | tuple[int, int], batch: Req
) -> None:
    if self.server_args.enable_breakable_cuda_graph:
        # Cache-DiT wraps transformer.forward with step-skipping control
        # flow that must not be baked into a captured CUDA graph.
        if self._cache_dit_requested():
            # warning_once 基于 _print_warning_once 实现进程级去重，
            # 从环境变量或请求级（如 MiniMax-H3 的 quality="high"）触发的
            # 首次抑制才会输出，避免逐请求刷日志。
            logger.warning_once(
                "Cache-DiT was requested but is disabled because breakable "
                "CUDA graphs are enabled."
            )
        return

    # 新请求到达时需要刷新 cache-dit 上下文；以下为原有逻辑，本 PR 未改动。
    if self._cache_dit_enabled:
        primary_num_steps, secondary_num_steps = self._cache_dit_step_counts(
```

```

        num_inference_steps
    )
    # ... refresh_context_on_transformer / refresh_context_on_dual_transformer ...
    return

```

python/sglang/multimodal_gen/test/unit/test_diffusion_bcg_padding.py

新增两个单元测试，验证请求了 Cache-DiT 且 BCG 启用时只告警一次、未请求时不告警，并验证 `stacklevel=2` 与进程级去重语义。

```

# 验证“请求了 Cache-DiT 但被 BCG 抑制”时只告警一次。
# _print_warning_once 是进程级去重的底层函数，测试前后清理其缓存，
# 防止其他用例或本用例重复执行时影响断言。
def test_bcg_warns_when_cache_dit_is_requested(self):
    self.stage.server_args = SimpleNamespace(enable_breakable_cuda_graph=True)
    _print_warning_once.cache_clear()
    self.addCleanup(_print_warning_once.cache_clear)

    with (
        # 模拟环境变量或请求级显式请求 Cache-DiT。
        patch.object(self.stage, "_cache_dit_requested", return_value=True),
        # warning_once 内部最终调用 logger.warning(..., stacklevel=2),
        # 这里 patch 住 warning，断言进程内只输出一次。
        patch.object(denoising_module.logger, "warning") as warning,
    ):
        # 连续两次调用（warmup 与非 warmup）都应被去重为一次。
        self.stage._maybe_enable_cache_dit(1, SimpleNamespace(is_warmup=True))
        self.stage._maybe_enable_cache_dit(1, SimpleNamespace(is_warmup=False))

        warning.assert_called_once_with(
            "Cache-DiT was requested but is disabled because breakable CUDA "
            "graphs are enabled.",
            stacklevel=2,
        )

```

评论区精华

本 PR 没有 review 评论（`review_comments_count = 0`），唯一评论是维护者 [mickqian](#) 的 [/tag-and-rerun-ci](#)，用于重跑 CI。技术决策全部沉淀在关联 Issue #34177 的讨论中：

“A startup-time check alone is not sufficient. Cache-DiT can also be requested per request ... the warning should also fire the first time a request asks for Cache-DiT while BCG suppresses it. Once per process is enough; this should not log per request.” 实现完整遵循了这三条约束：启动与请求级双覆盖、首次触发、进程级一次性。

- 告警触发时机与频率 (design): PR 在 `_maybe_enable_cache_dit` 的 BCG 早退分支内调用 `logger.warning_once`，同时覆盖环境变量启动路径与请求级路径，并依赖 `_print_warning_once` 实现进程级去重；新增 3 个单测分别覆盖两类路径。

风险与影响

- 风险：回归风险极低：模型执行路径零改动（仅新增日志分支），`test_diffusion_bcg_padding.py` 与 `test_minimax_h3_admission.py` 共 34 个用例在 Python 3.12 CPU 下通过。性能上，每个请求多一次 `_cache_dit_requested()` 判定，开销可忽略；告警输出被 `warning_once` 去重，热路径不会反复打日志，但需留意 `_cache_dit_requested()` 的实现本身不应过重。日志语义依赖 `logger.warning_once` 的进程级去重（`_print_warning_once`），若未来替换日志工具需保持去重语义，否则可能退化为逐请求刷日志。测试隔离方面，全局去重缓存通过 `cache_clear()` 清理，若其他测试并发使用同一全局函数可能产生交叉影响，当前单测顺序执行风险低。
- 影响：影响范围为开启 BCG 且请求 Cache-DiT 的 diffusion 用户（如 MiniMax-H3 高画质批次、Qwen-Image 等模型）：从“静默 1.00x”变为明确告警，显著降低配置冲突的排查成本。对团队而言，改动集中在去噪管线的一处早退分支，维护面小，且为后续 Cache-DiT 与 BCG 兼容性改进提供了明确的告警入口。
- 风险标记：热路径新增判定分支，告警去重依赖日志工具，全局日志缓存跨用例污染

关联脉络

- PR #34121 [Diffusion] Fix cache-first fast path accepting a metadata-only snapshot: 同属 diffusion 运行时缓存行为修复线，强调 cache 静默失效的用户可观测性。
- PR #34650 feat(diffusion): rebuild MiniMax-H3 AdaLN outputs on demand: 改动了 MiniMax-H3 模型管线与 diffusion 运行时，与本 PR 的请求级 `quality="high"` 挂载路径直接相关。