

PR #30584 完整报告

sgl-project/sglang

Fix diffusion BCG lifetime and add Z-Image-Turbo CI

合并时间: 2026-07-10 21:20

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30584>

执行摘要

- 一句话: 修复 diffusion BCG 输出生命周期并新增 CI 测试
- 推荐动作: 建议仔细阅读 `breakable_cuda_graph.py` 中的 `eager_on_graph` 实现, 理解桥接缓冲区生命周期管理的重要性。新增的 `test_eager_output_is_held_strongly_for_replay_bridge` 是一个优秀的回归测试示范, 值得在其他类似场景中推广。CI 的 standalone 组织方式也值得参考。

功能与动机

PR #27436 启用 diffusion BCG 后, Z-Image-Turbo 在禁用 `torch.compile/offload` 时出现 segfault, 根因是 eager break 输出被弱引用, replay 时复制到已释放 CUDA 地址。此 PR 保持强引用修复该问题, 并添加 CI 测试预防回归。

实现拆解

1. 修复桥接缓冲区生命周期: 在 `breakable_cuda_graph.py` 的 `eager_on_graph` 装饰器中, 将 `captured_output` 从弱引用 (`_weak_ref_if_tensor(output)`) 改为强引用 (`output`), 确保 replay 时 bridge buffer 地址有效。
2. 增强弱引用和复制函数: `_weak_ref_if_tensor` 和 `_copy_output` 新增对 tuple/list 的递归支持, 使这些工具能正确处理更复杂的输出结构。
3. 修复 Qwen attention mask 元数据: 在 `qwen_image.py` 中添加 `_attn_mask_meta_local_pad` 辅助函数, 正确区分 `DynamicVarlenMaskMeta` 类型与普通 dict, 避免 BCG 场景下 SP padding 计算错误。
4. 新增回归测试: 在 `test_breakable_cuda_graph.py` 中添加 `test_eager_output_is_held_strongly_for_replay_bridge`, 直接验证 eager 输出被强引用。在 `test_diffusion_bcg_padding.py` 中添加 `test_qwen_dynamic_varlen_meta_is_not_tail_pad_meta` 和 `test_image_generation_models_are_registered_as_bcg_supported`。
5. 端到端 CI 测试: 新增 `test_diffusion_bcg_zimage_turbo.py`, 通过 `sglang generate` 命令真实运行 Z-Image-Turbo BCG 生成, 检查 native backend、BCG capture 成功、像素生成成功。并在 GitHub Actions 中添加独立的 `bcg-diffusion job (H100)`, 配置为 STANDALONE。

关键文件:

- python/sglang/srt/model_executor/runner_backend_utils/breakable_cuda_graph/breakable_cuda_graph.py (模块 调度器; 类别 source; 类型 core-logic; 符号 `_weak_ref_if_tensor`, `_copy_output`, `eager_on_graph`) : 核心修复文件: 调整 eager 输出引用策略 (弱→强), 增强 `_weak_ref_if_tensor` 和 `_copy_output` 对 tuple/list 的支持。
- python/sglang/multimodal_gen/test/single_test_file/test_diffusion_bcg_zimage_turbo.py (模块 测试; 类别 test; 类型 test-coverage; 符号 `TestDiffusionBCGZImageTurbo`, `test_zimage_turbo_true_bcg_generate`) : 新增端到端 BCG 测试文件, 验证真实 Z-Image-Turbo 模型在 BCG 模式下完整生成流水线。
- python/sglang/multimodal_gen/runtime/models/dits/qwen_image.py (模块 模型; 类别 source; 类型 data-contract; 符号 `_attn_mask_meta_local_pad`) : 修复 Qwen 模型在 BCG 场景下的 attention mask 元数据判空逻辑, 添加 `_attn_mask_meta_local_pad` 辅助函数。
- python/sglang/multimodal_gen/test/unit/test_diffusion_bcg_padding.py (模块 测试; 类别 test; 类型 test-coverage; 符号 `test_qwen_dynamic_varlen_meta_is_not_tail_pad_meta`, `test_image_generation_models_are_registered_as_bcg_supported`) : 新增两个单元测试: 验证 `_attn_mask_meta_local_pad` 行为、验证 BCG 支持的模型注册表。
- test/registered/cuda_graph/breakable/test_breakable_cuda_graph.py (模块 测试; 类别 test; 类型 test-coverage; 符号 `test_eager_output_is_held_strongly_for_replay_bridge`, `scale`) : 添加回归测试 `test_eager_output_is_held_strongly_for_replay_bridge`, 验证 eager 输出被强引用。
- .github/workflows/pr-test-multimodal-gen.yml (模块 部署; 类别 infra; 类型 infrastructure) : 新增 bcg-diffusion standalone job, 运行在 1-gpu-h100, 执行端到端 BCG 测试。

关键符号: `_weak_ref_if_tensor`, `_copy_output`, `eager_on_graph`, `_attn_mask_meta_local_pad`, `test_zimage_turbo_true_bcg_generate`, `test_eager_output_is_held_strongly_for_replay_bridge`, `test_qwen_dynamic_varlen_meta_is_not_tail_pad_meta`, `test_image_generation_models_are_registered_as_bcg_supported`

关键源码片段

[python/sglang/srt/model_executor/runner_backend_utils/breakable_cuda_graph/breakable_cuda_graph.py](#)

核心修复文件: 调整 eager 输出引用策略 (弱→强), 增强 `_weak_ref_if_tensor` 和 `_copy_output` 对 tuple/list 的支持。

```
def _weak_ref_if_tensor(x):
    """Return a weak-ref tensor view for tensors; recursively handle tuples/lists."""
    if torch.is_tensor(x):
        from sglang.srt.compilation.weak_ref_tensor import weak_ref_tensors
        return weak_ref_tensors(x)
    # 新增递归支持 tuple/list, 确保中间层输出也能正确弱引用
    if isinstance(x, tuple):
```

```

        return tuple(_weak_ref_if_tensor(e) for e in x)
    if isinstance(x, list):
        return [_weak_ref_if_tensor(e) for e in x]
    return x

```

```

def eager_on_graph(enable: bool):
    def decorator(inner: Callable):
        def wrapper(*args, **kwargs):
            ...
            output = inner(*args, **kwargs)
            # === 修复关键：将弱引用改为强引用 ===
            # 之前的代码使用 captured_output = _weak_ref_if_tensor(output),
            # 导致 bridge buffer 在 replay 时指向已释放内存。
            # 现在直接保留强引用，确保下一个 segment 的输入地址有效。
            captured_output = output

            def replay_fn():
                new_out = captured_inner(*captured_args, **captured_kwargs)
                return _copy_output(captured_output, new_out)

            capture.cuda_graph._break_fns.append(replay_fn)
            ...
        return wrapper
    return decorator

```

python/sglang/multimodal_gen/test/single_test_file/test_diffusion_bcg_zimage_turbo.py

新增端到端 BCG 测试文件，验证真实 Z-Image-Turbo 模型在 BCG 模式下完整生成流水线。

```

class TestDiffusionBCGZImageTurbo(CustomTestCase):
    def test_zimage_turbo_true_bcg_generate(self):
        # 构建完整 sglang generate 命令，启用 BCG 并禁用 torch.compile/offload
        cmd = [
            "sglang", "generate",
            "--backend", "sglang",
            "--model-path", DEFAULT_SMALL_MODEL_NAME_FOR_TEST,
            "--prompt", "...",
            "--width", "512", "--height", "512",
            "--enable-breakable-cuda-graph",
            "--bcg-text-buckets", "128",
            "--enable-torch-compile", "false",
            "--dit-layerwise-offload", "false",
            "--dit-cpu-offload", "false",
            "--perf-dump-path", str(perf_path),
        ]
        result = subprocess.run(cmd, ..., timeout=300)
        # 断言：成功退出、使用 native 后端、BCG capture 成功、像素生成成功
        self.assertEqual(result.returncode, 0)

```

```
self.assertNotIn("Falling back to diffusers backend", result.stdout)
self.assertNotIn("[Diffusion BCG] capture failed", result.stdout)
self.assertIn("[Diffusion BCG] captured", result.stdout)
self.assertIn("Pixel data generated successfully", result.stdout)
# 验证 perf dump 包含 DenoisingStage
perf = json.loads(perf_path.read_text())
self.assertIn("DenoisingStage", {s.get("name") for s in perf.get("steps", [])})
```

评论区精华

唯一的 review 讨论围绕测试组织：mickqian 建议将 `bcg-diffusion` 测试加入 `STANDALONE_FILES` 以避免 fallback-estimate 噪声。BBuf 已采纳并在 commit `684b896ef0` 中实现，同时保留了 `run_suite.py --suite bcg-diffusion` 的兼容性。

- `bcg-diffusion` 测试组织方式 (testing): BBuf 采纳并修改：移动 `bcg-diffusion` 到 `STANDALONE_FILES`，保留空 parametrized 入口以维持 `run_suite.py` 兼容。

风险与影响

- 风险：
 - 强引用内存泄漏风险：保持强引用虽修复了段错误，但若桥接缓冲区在 capture 后不再使用，强引用会阻止其释放。但 bridge buffer 本质是下一个 segment 的输入，在完整 graph replay 完毕前必须存活，因此当前改动合理。
 - 新CIjob稳定性：`bcg-diffusionjob`运行真实Z-Image-Turbo生成，可能因GPU资源、环境变量等不稳定，但作为 standalone 测试可控制失败影响。
 - Qwen 辅助函数影响范围：`_attn_mask_meta_local_pad` 替换了内联表达式，仅影响 SP 场景下的 padding 计算，功能等价，风险低。
- 影响：
 - 用户影响：修复了 Z-Image-Turbo 用户启用 BCG 时的崩溃问题；Qwen 模型 BCG 路径也能正确处理掩码元数据。
 - 系统影响：CI 新增 standalone job，增加总测试时长但隔离失败域。
 - 团队影响：未来修改 BCG 相关代码时，必须确保 eager 输出桥接缓冲区的引用策略正确，新增的回归测试提供了防护。
 - 风险标记：核心路径变更，新 CI 依赖 GPU 环境

关联脉络

- PR #27436 [diffusion] Enable breakable CUDA graph (BCG) for diffusion DiTs: 该 PR 首次引入 diffusion BCG，但引入了本 PR 修复的 lifetime bug。本 PR 基于其代码基线修复问题。
- PR #30016 [perf] Enable torch.compile by default when performance-mode speed: 该 PR 改变了 performance_mode 语义，使 BCG 测试环境需要显式禁用 torch.compile，本 PR 的测试命令中包含 `--enable-torch-compile false` 以应对。