

PR #27524 完整报告

sgl-project/sglang

[diffusion] Progressive resolution growing for Image and Video models via GPU DCT upsampling
with up to 2X+ speedup

合并时间: 2026-06-08 20:44

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/27524>

执行摘要

- 一句话: 渐进分辨率扩散加速, 支持 5 种模型最高 2.32x加速
- 推荐动作: 值得精读。核心设计模式(钩子基类 + 路由器)适合作为框架功能扩展的范本。DCT 上采样和贝叶斯最优转换的数学实现具有参考价值。建议关注频谱系数拟合流程和 Wan 视频的对齐逻辑, 这两处最有可能需要根据实际场景调整。

功能与动机

Transformer attention 的复杂度是 $O(n^2)$ 序列长度。对于图像 / 视频扩散模型, 早期去噪步骤几乎只在低频区域运行——高频空间细节尚未被扩散过程激活。在这些步骤上使用全分辨率计算是纯粹的浪费。基于 Spectral Progressive Diffusion (arXiv 2605.18736)。

实现拆解

1. 核心数学与频谱操作: 在 `python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/spectral_ops.py` 中实现 GPU DCT-II/IDCT-II (通过 `torch.fft`)。在 `scheduler_utils.py` 中实现贝叶斯最优阶段转换计算函数 `compute_stage_transitions`、`find_transition_steps` 和 `reset_scheduler_at_step`。
2. 基类 `ProgressiveDenoisingStage`: 在 `denoising.py` 中定义, 继承 `DenoisingStage`, 通过多个扩展钩子 (`_unpack_latent`、`_repack_latent`、`_latent_scale_factor`、`_on_resolution_change`、`_generate_initial_noise`) 支持模型特定子类。核心去噪循环在 `forward` 中执行多阶段粗到细流程, 阶段间调用 `apply_upsample`。
3. 模型特定子类: 为每个模型添加 `FluxProgressiveDenoisingStage` (`flux.py`)、`Flux2ProgressiveDenoisingStage` (`flux_2.py`, 行优先 pack/unpack)、`ZImageProgressiveDenoisingStage` (`zimage.py`, 5D 潜变量)、`WanProgressiveDenoisingStage` (`wan.py`, 视频时空对齐)、`QwenImageProgressiveDenoisingStage` (`qwen_image.py`, 2x2 patchify)。每个子类处理独有的潜变量布局、RoPE 更新和分辨率变化钩子。
4. Pipeline 路由与参数: 在每个模型的 pipeline 文件 (`flux.py`、`flux_2.py`、`zimage_pipeline.py`、`wan_pipeline.py`、`qwen_image.py`) 中, 将直接使用的 `DenoisingStage` 替换为 `*DenoisingStageRouter`, 根据批次 `progressive_mode` 动态选择全分辨率或渐进阶段。修改 `composed_pipeline_base.py` 添加 `add_progressive_denoising_stage` 支持。在 `sampling_params.py` 添加

`progressive_mode`、`progressive_levels`、`progressive_delta` 字段和 CLI 标志。

5. 测试与文档：添加单元测试 `test_progressive.py`（覆盖格式转换、数学计算、参数验证），`conftest.py` 提供默认 `ServerArgs`。编写用户文档 `progressive_resolution.mdx` 和基准测试指南。

关键文件：

- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/denoising.py`（模块 核心逻辑；类别 source；类型 core-logic；符号 `is_progressive_resolution_mode`, `unpack_2x2_latent`, `pack_2x2_latent`, `_P_omega`）：核心基类 `ProgressiveDenoisingStage` 和多阶段去噪循环，定义了钩子扩展点，是渐进分辨率的逻辑中枢。
- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/flux_2.py`（模块 核心逻辑；类别 source；类型 core-logic；符号 `_flux2_unpack`, `_flux2_pack`, `Flux2ProgressiveDenoisingStage`, `init`）：FLUX.2 特定的渐进去噪阶段，展示行优先潜变量 `pack/unpack` 和 `_latent_scale_factor` 钩子。
- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/wan.py`（模块 核心逻辑；类别 source；类型 core-logic；符号 `WanProgressiveDenoisingStage`, `init`, `_latent_scale_factor`, `_unpack_latent`）：Wan T2V 视频模型渐进阶段，处理 5D 时空潜变量、空间对齐和 no-op 分辨率变化钩子。
- `python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/spectral_ops.py`（模块 频谱运算；类别 source；类型 core-logic；符号 `dct_1d`, `idct_1d`, `dct_2d`, `idct_2d`）：GPU 原生 DCT-II / IDCT-II 实现，所有上采样的核心数学运算，精度匹配 `scipy`。
- `python/sglang/multimodal_gen/runtime/pipelines_core/composed_pipeline_base.py`（模块 Pipeline 基类；类别 source；类型 core-logic；符号 `add_progressive_denoising_stage`, `create_stage`）：修改 pipeline 基类以支持渐进阶段注册，是路由改造的关键入口。

关键符号：`is_progressive_resolution_mode`, `unpack_2x2_latent`, `pack_2x2_latent`, `_P_omega`, `_activation_time`, `compute_stage_transitions`, `find_transition_steps`, `reset_scheduler_at_step`, `dct_1d`, `idct_1d`, `dct_2d`, `idct_2d`, `dct_upsample_2d`, `apply_upsample`, `ProgressiveDenoisingStage.forward`, `FluxProgressiveDenoisingStage._unpack_latent`, `Flux2ProgressiveDenoisingStage._latent_scale_factor`, `WanProgressiveDenoisingStage.forward`, `ZImageProgressiveDenoisingStage._generate_initial_noise`, `QwenImageProgressiveDenoisingStage._on_resolution_change`, `_FluxDenoisingStageRouter.component_uses`

关键源码片段

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

核心基类 ProgressiveDenoisingStage 和多阶段去噪循环，定义了钩子扩展点，是渐进分辨率的逻辑中枢。

```
def compute_stage_transitions(
    delta: float,
    n_levels: int,
    A: float,
    beta: float,
    H_lat: int,
    W_lat: int,
) -> dict[int, float]:
    # 根据贝叶斯最优准则计算每个阶段的转换 sigma 阈值
    #  $P(\omega) = A * |\omega|^{-\beta}$  为功率谱经验拟合
    stage_sigmas: dict[int, float] = {1: 1.0}
    num_stages = n_levels + 1
    for stage in range(2, num_stages + 1):
        # 计算上一阶段的空间频率 omega (取最小维的一半)
        H_prev = H_lat // (2 ** (num_stages - stage + 1))
        W_prev = W_lat // (2 ** (num_stages - stage + 1))
        w = min(H_prev, W_prev) // 2
        stage_sigmas[stage] = _activation_time(_P_omega(w, A, beta), delta)
    return stage_sigmas

def find_transition_steps(
    scheduler_sigmas: torch.Tensor,
    stage_sigmas: dict[int, float],
    n_steps: int,
) -> dict[int, int]:
    # 将 sigma 阈值映射到具体去噪步数
    sigmas_list = scheduler_sigmas.cpu().tolist() # 提前转 list 避免逐元素 Python 开销
    transition_steps: dict[int, int] = {}
    for stage, threshold in stage_sigmas.items():
        if stage == 1:
            continue
        found = n_steps
        for step_index in range(n_steps):
            if sigmas_list[step_index] <= threshold:
                found = step_index
                break
        transition_steps[stage] = found
    return transition_steps
```

[python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/flux_2.py](https://github.com/CompVis/stable-diffusion/blob/main/python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/flux_2.py)

FLUX.2 特定的渐进去噪阶段，展示行优先潜变量 pack/unpack 和 _latent_scale_factor 钩子。

```
def _flux2_unpack(latent: torch.Tensor, h_lat: int, w_lat: int) -> torch.Tensor:
    # packed [B, H_lat*W_lat, C] -> spatial [B, C, H_lat, W_lat] (行优先)
    B, _S, C = latent.shape
```

```

return latent.permute(0, 2, 1).reshape(B, C, h_lat, w_lat)

def _flux2_pack(x: torch.Tensor) -> torch.Tensor:
    # spatial [B, C, H_lat, W_lat] -> packed [B, H_lat*W_lat, C]
    B, C, H, W = x.shape
    return x.reshape(B, C, H * W).permute(0, 2, 1)

class Flux2ProgressiveDenoisingStage(ProgressiveDenoisingStage):
    """FLUX.2 渐进去噪阶段，行优先 pack/unpack + RoPE 更新"""

    def _latent_scale_factor(self, server_args: ServerArgs) -> int:
        # FLUX.2 潜变量空间维度是像素的 1/(vae_scale_factor * 2)
        return server_args.pipeline_config.vae_config.arch_config.vae_scale_factor * 2

    def _unpack_latent(self, latent, h_lat, w_lat):
        return _flux2_unpack(latent, h_lat, w_lat)

    def _repack_latent(self, x_spatial, h_lat, w_lat, batch, server_args):
        return _flux2_pack(x_spatial)

```

python/sglang/multimodal_gen/runtime/pipelines_core/stages/progressive_resolution/wan.py

Wan T2V 视频模型渐进阶段，处理 5D 时空潜变量、空间对齐和 no-op 分辨率变化钩子。

```

class WanProgressiveDenoisingStage(ProgressiveDenoisingStage):
    """Wan T2V 渐进去噪阶段，无 pack/unpack，仅空间上采样"""

    def _latent_scale_factor(self, server_args: ServerArgs) -> int:
        # WanVAEArchConfig 使用 spatial_compression_ratio 而非 vae_scale_factor
        arch = server_args.pipeline_config.vae_config.arch_config
        return getattr(arch, "vae_scale_factor", None) or getattr(
            arch, "spatial_compression_ratio", 8
        )

    def _unpack_latent(self, latent, h_lat, w_lat):
        return latent # 已经是 [B, C, T, H, W]

    def _repack_latent(self, x_spatial, h_lat, w_lat, batch, server_args):
        return x_spatial

    def _on_resolution_change(self, ctx, batch, server_args, new_h_pixel, new_w_pixel):
        pass # Wan T2V 没有空间位置编码需要更新

    def forward(self, batch: Req, server_args: ServerArgs) -> Req:
        # 确保每个渐进阶段潜变量 H/W 为偶数 (Conv3d stride=(1,2,2) 要求)
        mode = getattr(batch, "progressive_mode", "fullres") or "fullres"
        if not is_progressive_resolution_mode(mode):
            return super().forward(batch, server_args)
        levels = getattr(batch, "progressive_levels", 1)

```

```
vae_scale = self._latent_scale_factor(server_args)
align_pixels = vae_scale * (2**levels) * 2
# 向下对齐, 但至少为 align_pixels (防止零分辨率)
h_aligned = max((batch.height // align_pixels) * align_pixels, align_pixels)
w_aligned = max((batch.width // align_pixels) * align_pixels, align_pixels)
batch.height = h_aligned
batch.width = w_aligned
return super().forward(batch, server_args)
```

评论区精华

Gemini Code Assist 审查提出了 5 个技术问题:

- 重复测试类: `TestProgressiveSamplingParams` 出现在两个测试文件中, 批注建议删除重复。
- `.item()` 效率: 在 `scheduler_utils.py` 的嵌套循环中使用 `.item()` 逐个访问张量元素, 批注建议替换为 `.tolist()` 以提升性能。
- `torch.Generator` 跨平台兼容性: 在 `upsample.py` 中创建 `Generator` 时指定 `device` 可能导致非 CUDA 设备崩溃, 批注建议在 CPU 上生成噪声再转移到目标设备。
- Wan 零分辨率边缘情况: 如果 `batch.height` 或 `width` 小于对齐像素, 对齐后可能得到 0, 批注建议添加 `max` 防护。
- 负嵌入批处理维度: 在 `text_encoding.py` 中, 2-D 负嵌入直接返回导致 `cfg` 拼接形状不匹配, 批注提供修复建议。

以上问题在后续提交中全部解决: 重复类被移除, `.item()` 替换为 `.tolist()`, `Generator` 改为 CPU 创建, Wan 对齐添加 `max` 防护, 负嵌入修复已包含。此外, mickqian 建议聚合分散的单元测试, 已通过 commit 28c3b157 合并到 `test_progressive.py`。

- 重复测试类 `TestProgressiveSamplingParams` (testing): 后续提交中移除重复定义。
- `.item()` 在嵌套循环中的性能问题 (performance): 已替换为 `.tolist()`。
- `torch.Generator` 跨平台兼容性 (correctness): 已修改为在 CPU 上生成噪声。
- Wan 零分辨率边缘情况 (correctness): 已添加 `max(..., align_pixels)` 防护。
- 负嵌入批处理维度不匹配 (correctness): 已修复。
- 聚合单元测试 (testing): 测试已合并到 `test_progressive.py`。

风险与影响

- 风险:
 - 视觉质量回归风险: DCT 上采样是近似逆问题, 高 δ 值可能导致细节损失。默认 `fullres` 模式不受影响。
 - 频谱系数依赖外部拟合: FLUX.1 和 Wan 的系数来自特定数据集, Qwen-Image 使用占位系数, 可能不准确导致次优阶段转换。
 - 缺少多 GPU 测试覆盖: diffusion 模型通常运行在单卡, 多 GPU 场景的 `progressive` 路由未充分测试。
 - Wan 分辨率对齐限制: Wan 的 patch 嵌入要求每个阶段潜变量 H/W 为偶数, 对齐逻辑可能导致最终像素非标准。

- 设备兼容性：DCT 操作依赖 `torch.fft`，在 NPU/AMD 等非 CUDA 设备上可能回退或精度不同。
- 影响：
 - 用户影响：默认行为完全不变。启用 `progressive` 模式后生成速度显著提升（最高 2.32x），但视觉质量可能略有下降（取决于 δ ）。
 - 系统影响：新增约 2500 行核心源码，但模块化设计（钩子、路由器）对现有 pipeline 侵入性低。5 个 pipeline 文件修改为路由模式，但原有逻辑完全保留。
 - 团队影响：添加新扩散模型需要实现特定的钩子（`pack/unpack`、分辨率变化、噪声生成），还需要为 VAE 拟合功率谱系数 A 和 β 。
 - 风险标记：视觉质量回归风险，频谱系数依赖外部拟合，缺少多 GPU 测试覆盖，Wan 分辨率对齐限制，设备兼容性

关联脉络

- PR #26961 [WIP] Spectral Progressive Diffusion (old PR): 该 PR 的旧版本链接，PR body 中明确引用，是同一功能线的早期提交。