

PR #22786 完整报告

sgl-project/sglang

[AMD][diffusion] Add FlyDSL fused normalization kernels for ROCm diffusion models optimization

合并时间: 2026-06-08 17:42

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/22786>

执行摘要

- 一句话: 为 AMD ROCm 添加 FlyDSL 融合归一化核, 优化扩散模型
- 推荐动作: 建议精读此 PR, 尤其是 fused_residual_norm.py 中 FlyDSL 核的实现和寄存器缓存优化技术, 以及 layernorm.py 中多级 fallback 的设计模式, 值得在跨平台多后端开发中参考。

功能与动机

为 AMD ROCm 扩散模型优化归一化层性能。现有 CUDA/CUTLASS 融合核在 ROCm 上不可用, 需要原生 ROCm 融合核以利用硬件潜力。PR body 明确指出 "Add AMD FlyDSL fused normalization kernels optimized for ROCm diffusion pipelines"。

实现拆解

1. 核心核实现: 在 python/sglang/jit_kernel/diffusion/flydsl/fused_residual_norm.py 中使用 FlyDSL DSL 编写了两个核函数: flydsl_fused_residual_norm_scale_shift (融合残差加、门控乘、归一化、scale*shift) 和 flydsl_norm_scale_shift (融合归一化、scale*shift)。核函数利用寄存器缓存优化, Phase 1 计算得到的 f32 中间值保留在寄存器中, Phase 2 直接重用, 避免重新读取 HBM。
2. 编译缓存与 Fallback: 通过 _get_or_compile 缓存编译结果, 通过 launch_fused_norm 处理参数和降级。当维度不满足 5120 对齐或 flydsl 包未导入时, 优雅降级到 native PyTorch 实现。
3. 集成到现有层: 在 python/sglang/multimodal_gen/runtime/layers/layernorm.py 中, 修改 RMSNorm 和 FusedScaleResidualNormScaleShift 的 forward_hip 方法, 添加环境变量 SGLANG_USE_ROCM_FLYDSL 控制开关、导入保护和维度对齐检查。
4. 单元测试: 新增 python/sglang/jit_kernel/tests/diffusion/test_flydsl_fused_norm.py, 包含两个参数化测试用例, 覆盖多种 norm_type、batch 和 seq_len 组合, 对比 FlyDSL 输出与 PyTorch 参考输出, 使用宽松容忍度 (atol=5e-2, rtol=5e-2)。测试注册为 AMD CI。

关键文件:

- python/sglang/jit_kernel/diffusion/flydsl/fused_residual_norm.py (模块 融合核; 类别 source; 类型 core-logic; 符号 _v, _build_fused_norm_module, flydsl_fused_residual_norm_ss_kernel, launch_fused_norm): 核心实现, 定义了

FlyDSL 融合归一化核和包装函数

- python/sglang/multimodal_gen/runtime/layers/layernorm.py (模块 扩散层; 类别 source; 类型 dependency-wiring; 符号 forward_hip) : 修改 forward_hip 以集成 FlyDSL 核, 包含环境变量开关、导入保护和维度降级
- python/sglang/jit_kernel/tests/diffusion/test_flydsl_fused_norm.py (模块 测试; 类别 test; 类型 test-coverage; 符号 _ref_rms_norm, _ref_fused_residual_norm_ss, _ref_norm_ss, test_fused_residual_norm_scale_shift) : 单元测试, 验证 FlyDSL 核的正确性

关键符号: _build_fused_norm_module, flydsl_fused_residual_norm_ss_kernel, launch_fused_norm, _get_or_compile, flydsl_fused_residual_norm_scale_shift, flydsl_norm_scale_shift, forward_hip (RMSNorm), forward_hip (FusedScaleResidualNormScaleShift)

关键源码片段

python/sglang/jit_kernel/diffusion/flydsl/fused_residual_norm.py

核心实现, 定义了 FlyDSL 融合归一化核和包装函数

```
"""FlyDSL fused normalization kernels for AMD ROCm (gfx950)."""
```

```
WARP_SIZE = 64
```

```
_VEC = 8
```

```
_NUM_WAVES = 10
```

```
FLYDSL_NORM_MIN_ALIGNED_DIM = WARP_SIZE * _NUM_WAVES * _VEC # 5120
```

```
def _build_fused_norm_module(D: int, is_rms: bool, has_gate: bool, has_weight: bool):
```

```
    # 设置 tiling 参数, 要求 D 是 5120 的倍数
```

```
    VEC = _VEC
```

```
    NUM_WAVES = _NUM_WAVES
```

```
    BLOCK = NUM_WAVES * WARP_SIZE # 640
```

```
    assert D % FLYDSL_NORM_MIN_ALIGNED_DIM == 0, f"D must be multiple of {FLYDSL_NORM_MIN_ALIGNED_DIM}"
```

```
    NUM_ITERS = D // (BLOCK * VEC)
```

```
@flyc.kernel(known_block_size=[BLOCK, 1, 1])
```

```
def flydsl_fused_residual_norm_ss_kernel(
```

```
    y_ptr: fx.Tensor, res_out_ptr: fx.Tensor, res_ptr: fx.Tensor,
```

```
    x_ptr: fx.Tensor, gate_ptr: fx.Tensor, weight_ptr: fx.Tensor,
```

```
    bias_ptr: fx.Tensor, scale_ptr: fx.Tensor, shift_ptr: fx.Tensor,
```

```
    total_rows: Int32, gate_stride: Int32, scale_stride: Int32, shift_stride: Int32,
```

```
):
```

```
    row = fx.block_idx.x
```

```
    tid = fx.thread_idx.x
```

```
    # 创建 buffer 资源
```

```
    y_rsrc = buffer_ops.create_buffer_resource(y_ptr, max_size=True)
```

```
    # ... 省略中间代码 ...
```

```

# Phase 1: 计算 residual + gate * x, 累积部分和 / 平方和, 保留 f32 值在寄存器
# Phase 2: 使用寄存器中的 f32 值计算 RMSNorm/LayerNorm 和 scale*shift,
# 避免重新读取 HBM, 节省约 20% 带宽
return flydsl_fused_residual_norm_ss_kernel

```

python/sglang/multimodal_gen/runtime/layers/layernorm.py

修改 forward_hip 以集成 FlyDSL 核, 包含环境变量开关、导入保护和维度降级

```

def forward_hip(self, residual, x, gate, shift, scale):
    # 环境变量开关, 默认不使用 FlyDSL
    if not _use_rocm_flydsl:
        return self.forward_native(residual, x, gate, shift, scale)
    # 导入保护: 若 flydsl 包未安装则降级
    try:
        from sglang.jit_kernel.diffusion.flydsl.fused_residual_norm import (
            FLYDSL_NORM_MIN_ALIGNED_DIM,
            flydsl_fused_residual_norm_scale_shift,
        )
    except ImportError:
        return self.forward_native(residual, x, gate, shift, scale)
    # 维度对齐检查: 仅当 hidden_size 是 5120 的倍数时才使用 FlyDSL
    if x.shape[-1] % FLYDSL_NORM_MIN_ALIGNED_DIM != 0:
        return self.forward_native(residual, x, gate, shift, scale)
    # 调用 FlyDSL 融合核
    return flydsl_fused_residual_norm_scale_shift(
        residual.contiguous(),
        x.contiguous(),
        gate.contiguous() if isinstance(gate, torch.Tensor) else None,
        _ensure_contiguous(self.norm.weight),
        _ensure_contiguous(self.norm.bias),
        scale.contiguous(),
        shift.contiguous(),
        self.norm_type,
        self.eps,
    )

```

评论区精华

Review 中主要有以下讨论:

- Dockerfile 依赖 (HaiShaw): 要求添加 rocm.Dockerfile 安装 FlyDSL。作者通过兼容性修复 (适配 flydsl>=0.1.5) 解决了问题, 最终无需修改 Dockerfile。
- 性能优化建议 (gemini-code-assist[bot]): 建议将 batch 循环移至 GPU 网格以减少 CPU 开销、移除 forward_hip 中的冗余 contiguous 调用和调试打印、避免在 gate 为 None 时重复分配 dummy 张量、以及放宽维度对齐断言。这些建议并未全部被采纳, 但最终 HaiShaw 批准了 PR。
- Dockerfile 安装 FlyDSL 依赖 (infra): 无需修改 Dockerfile, 兼容性已解决。
- batch 循环 CPU 开销 (performance): 未明确是否采纳, 但 PR 最终被批准。

- 连续调用和调试打印清理 (style): 未明确采纳, 最终代码中仍保留 contiguous 调用。

风险与影响

- 风险:
 1. 维度对齐限制: 核要求 hidden_size 是 5120 的倍数, 不满足时会 fallback 到 native 实现。若用户模型 hidden_size 较小或不是 5120 倍数, 无法获得加速。
 2. 集成路径未在 CI 中测试: PR-CI 未设置 SGLANG_USE_ROCM_FLYDSL 环境变量, 从 layernorm.py 到 FlyDSL 核的集成分支从未被执行, 可能引入未发现的兼容性问题。
 3. 可选依赖 flydsl: 环境需要安装 flydsl 包 ($\geq 0.1.5$), 增加了部署复杂度。 - 影响: 用户影响: AMD ROCm 用户启用环境变量后, 在扩散模型 (如 Wan2.2 T2V) 推理的 Denoising 阶段可获得约 3-10% 的加速 (总时间约 1-3%)。未启用或非 AMD 平台无影响。系统影响: 新增约 1k 行 Python 代码, 引入可选依赖 flydsl。团队影响: 为 AMD 扩散优化建立了基础设施, 未来可以类似方式添加更多融合核。 - 风险标记: 维度对齐限制, 集成路径未测试, 可选依赖 flydsl

关联脉络

- 暂无明显关联 PR