

PR #29382 完整报告

sgl-project/sglang

[CPU] use faster exp in silu_and_mul

合并时间: 2026-06-29 09:38

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29382>

执行摘要

该 PR 将 CPU 端 `silu_and_mul` 激活函数的向量化实现中的 `exp` 替换为 `exp_u20` 近似, 实现 6% 至 29% 的性能提升。变更仅涉及一行代码, 风险低, 收益明确。

功能与动机

`silu_and_mul` 是 LLM gated MLP 中频繁使用的激活函数。在 CPU 推理中, 其向量化路径使用 `std::exp` (基于 sleef u10 实现) 计算指数部分。PyTorch 的 `Vectorized<float>` 提供了 `exp_u20` 近似函数, 精度为 20 ULP 但速度更快。该 PR 旨在利用这一近似加速 CPU 推理, 同时保持数值结果在可接受范围内。

实现拆解

1. 定位变更点: 文件 `sgl-kernel/csrc/cpu/activation.cpp` 中 `silu_and_mul_cpu` 函数的向量化 `lambda`。
2. 替换指数函数: 将 `x.neg().exp()` 改为 `x.neg().exp_u20()`, 标量路径的 `std::exp(-x)` 保持不变以保留精度回退。
3. 测试验证: 执行 `test/registered/cpu/test_activation.py` 通过, 并提供了详细的精度对比和性能基准 (见 PR body 表格)。

`sgl-kernel/csrc/cpu/activation.cpp`

核心变更文件, 替换 `silu_and_mul` 向量化路径中的 `exp` 为 `exp_u20`

```
// 文件 : sgl-kernel/csrc/cpu/activation.cpp
// 改动 : 将向量化版本中的 .exp() 替换为 .exp_u20(),
// exp_u20 是 PyTorch 提供的更快近似, 精度约 20 ULP,
// 标量回退路径仍使用 std::exp 以保证数值稳定性。
```

```
at::Tensor silu_and_mul_cpu(at::Tensor& input) {
    auto sizes = input.sizes().vec();
    int64_t last_dim = input.ndimension() - 1;
    int64_t d = sizes[last_dim] / 2;
    sizes[last_dim] = d;
    int64_t num_tokens = input.numel() / input.size(-1);
    at::Tensor out = at::empty(sizes, input.options());
```

```
AT_DISPATCH_REDUCED_FLOATING_TYPES(input.scalar_type(), "silu_and_mul", [&] {
    using Vec = at::vec::Vectorized<float>;
    act_and_mul_kernel_impl(
```

```

    out.data_ptr<scalar_t>(),
    input.data_ptr<scalar_t>(),
    num_tokens,
    d,
    // 标量回退：使用标准 exp，确保精度
    [](float x) { return x / (1.f + std::exp(-x)); },
    // 向量化路径：使用 exp_u20 近似，加速推理
    [](Vec x) { return x / (Vec(1.f) + x.neg().exp_u20()); });
});
return out;
}

```

评论区精华

无 review 讨论。

风险与影响

- 精度风险：exp_u20 的误差约 20 ULP，可能在某些极端输入下与 exp 结果略有偏差。但 SiLU 激活函数对指数部分误差不敏感，实际影响可以忽略。
- 回归风险：仅修改一行，且经过测试验证，回归可能性极低。
- 影响：所有使用 CPU silu_and_mul 的模型将受益，加速可达 29%。

关联脉络

该 PR 是 CPU 内核性能优化的延续。类似地，[sgl-kernel](#) 中其他激活函数（如 [gelu_tanh_and_mul](#)）未来也可采用相同的近似策略以获得额外加速。