

PR #34106 完整报告

sgl-project/sglang

[jit_kernel] Fix missing JIT kernel namespaces

合并时间: 2026-08-08 22:15

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34106>

执行摘要

这是一次针对 #33400 "Move JIT kernels into namespace sglang" 全局迁移的修补型变更, 共改动 2 个 .cuh 头文件、净增加 6 行代码:

- 为 #32541 新增的单 token MoE 对齐内核 `align_single_token.cuh` 补上 namespace `sglang` 包裹 (原为匿名命名空间);
- 为 `diffusion` 的 `modulate_scale_shift.cuh` 在最内层伪命名空间之外补齐最外层 namespace `sglang`。

两处都只改命名空间包装、不改任何计算, 配套 `bit-exact` 测试在 H200 上 12 项全部通过。属于低风险、低影响、但必要的合规性修复, 延续了 JIT 内核命名空间统一约定。

功能与动机

PR body 明确说明这是 #33400 的后续修复:

Fix the JIT namespace break from #33400 for the single-token MoE kernel added in #32541. Fix the same helper-namespace migration break in the diffusion adaLN modulation kernel. Restore first-use JIT compilation without changing either kernel's computation.

33400 将 `python/sglang/kernels/jit/` 下所有 JIT C++ 统一迁入 namespace `sglang`, 并让 `load_jit` 在命名空间内输出 `TVM_FFI_DLL_EXPORT_TYPED_FUNC`, 因此 Python 侧调用 `kernel_name` 不再带 `sglang::` 前缀。这意味着任何仍停留在全局或匿名命名空间的内核, 都会在 JIT 首次编译时出现符号解析失败。

被遗漏的两个文件各有原因: `align_single_token.cuh` 是 #32541 在迁移之后新增的, 天然不参与 #33400 的扫描; `modulate_scale_shift.cuh` 在 #33400 中只做了内部伪命名空间 (`sglang_modulate_scale_shift`) 的嵌套化, 少包了一层最外层 `sglang`。

实现拆解

1. 补全 MoE 单 token 对齐内核命名空间 文件 `python/sglang/kernels/jit/csrc/moe/align_single_token.cuh`: 将顶部匿名 namespace `{ ... }` 改为 namespace `sglang { ... }`, 并在文

件末尾把 `} // namespace` 的注释更新为 `} // namespace sglang`。改动后 `AlignSingleTokenParams`、`AlignSingleTokenKernel` 与其余 JIT 内核一样处于 `sglang` 命名空间下，`load_jit` 生成的无前缀导出即可正确解析。

2. 补齐 diffusion modulation 内核外层命名空间 文件 `python/sglang/kernels/jit/csrc/diffusion/modulate_scale_shift.cuh`：在原有 `namespace sglang_modulate_scale_shift { namespace { ... } }` 结构之外，再包裹一层 `namespace sglang`，并在文件尾闭合。这样该内核路径从全局命名空间变为 `sglang::sglang_modulate_scale_shift`，与 #33400 对 `csrc/diffusion/` 伪命名空间的处理约定一致。
3. 验证与配套 无新增测试文件，但复用现有 `test_modulate_scale_shift.py`：H200 上清空 TVM-FFI 缓存后 12 项测试全部通过，覆盖 BF16/FP16 生产形状与边界形状，并要求与 eager PyTorch 逐位相等，证明修复不改变数值。pr-test 与 pr-test-extra 两个 CI 均通过。

`python/sglang/kernels/jit/csrc/moe/align_single_token.cuh`

32541 新增的单 token MoE 对齐内核，在 #33400 迁移时被遗漏，仍是匿名 namespace；本 PR 将其改为 `namespace sglang`，补齐 JIT 命名空间约定。

```
// python/sglang/kernels/jit/csrc/moe/align_single_token.cuh
// 修复 #33400 的命名空间迁移遗漏：该文件是 #32541 新增的
// 单 token MoE 对齐内核，原为匿名命名空间，改为 namespace sglang
#include <cstdint>

namespace sglang {

struct AlignSingleTokenParams {
    const int32_t* __restrict__ topk_ids; // [1, topk]
    // ... 其余字段未改动
};

struct AlignSingleTokenKernel {
    // ... 内核实现未做任何计算改动
};

} // namespace sglang
```

`python/sglang/kernels/jit/csrc/diffusion/modulate_scale_shift.cuh`

33400 只把内部伪命名空间 `sglang_modulate_scale_shift` 嵌套化，遗漏了最外层 `namespace sglang`；本 PR 补齐外层包裹，恢复 diffusion adaLN modulation 内核的首次编译。

```
// python/sglang/kernels/jit/csrc/diffusion/modulate_scale_shift.cuh
// 在伪命名空间 sglang_modulate_scale_shift 外层补齐 namespace sglang
#include <cstdint>
```

```

namespace sglang {

namespace sglang_modulate_scale_shift {
namespace {

struct ModulateScaleShiftKernel {
    // ... 内核实现未改动，bit-exact 测试保证与 eager PyTorch 逐位一致
};

} // namespace
} // namespace sglang_modulate_scale_shift

} // namespace sglang

```

评论区精华

该 PR 没有 review 评论，BBuf 直接 APPROVED。Issue 评论区只有两条 CI 机器操作：

```

mmangkad: /tag-and-rerun-ci BBuf: /rerun-test
test/registered/radix_cache/unified_radix_tree/test_unified_radix_cache_kl_dsv4.py

```

重跑结果通过。没有设计权衡或未解决疑虑。

风险与影响

- 回归风险低但存在：两个文件都是被多处 include 的 .cuh 头文件，若某调用方此前依赖匿名命名空间的全局可见性，补上 namespace sglang 后可能引发编译错误。不过 #33400 后所有 JIT 内核已统一该约定，方向正确。
- 数值零变化：modulate 内核有 bit-exact 测试兜底；align_single_token 虽无直接测试变更，但纯包装改动不涉及逻辑。
- 影响面限定在 JIT 首次编译：Restore first-use JIT compilation 意味着只有 fresh TVM-FFI cache 的场景受影响，已缓存部署无感知。
- 可维护性警示：此次遗漏说明 #33400 这类全局迁移很难覆盖迁移之后新增的文件，仓库已有的 test_kernels_namespace (#33400 中提到) 这类扫描测试应保持运行，以把 namespace 约定固化为 CI 防线。

关联脉络

- #33400 (Move JIT kernels into namespace sglang)：本 PR 是其直接遗漏补丁。该迁移当时虽做了全树 ::identifier 扫描，但无法覆盖后来新增的文件，也漏掉了 modulate_scale_shift.cuh 的外层包裹。
- #32541 ([Kimi] Support kimi-k3)：单 token MoE 对齐内核 align_single_token.cuh 正是随 K3 支持引入的；K3 这条功能线随后还关联了 #33903 (Inkling silu_and_mul 迁移纯 Triton) 和 #34045 (短卷积后端扩展) 等 JIT/ 内核工作。

整体看，本 PR 是 JIT 内核 namespace 统一演进中的一次快速收尾，价值在于提醒团队：大范围机械迁移需要配合可自动扫描的防回归机制。