

PR #35337 完整报告

sgl-project/sglang

[XPU][CI] key persistent JIT kernel cache by image content ID

合并时间: 2026-08-20 10:28

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/35337>

执行摘要

- 一句话: XPU CI 缓存按镜像 ID 键控, 修复 dlopen 过期 .so 失败
- 推荐动作: 值得精读, 尤其适合 XPU/Intel CI 维护者。重点看 `xpu_ci_start_container.sh` 对 `set -euo pipefail`、`root-owned` 文件与容器化清理的组合处理, 以及缓存键控的 fallback 设计; GDN kernel 的 `valid_state` 守卫可对照 PR #33431 的测试理解, 是一个典型的「测试驱动 kernel 边界修复」案例。

功能与动机

PR body 明确指出: Nightly image rebuilds swap the runtime libs that cached JIT .so files link against (例如 `libsycl.so.8` -> `libsycl.so.9`) , Triton 只按源码 hash 键控缓存, 旧 gpu-mask 缓存路径会 dlopen 旧镜像的过期 .so, 导致每个 XPU CI job 以 `OSError: libsycl.so.N: cannot open shared object file` 死亡。此外, commit 6340656 说明 PR #33431 新增的 `test_padded_state_index_is_skipped[all_padded]` 在 XPU 上确定性失败: 所有行均为 -1 哨兵时, 哨兵进入指针算术并访问 state pool 之前的内存, pool 被改写。

实现拆解

1. 缓存路径重新键控 (`scripts/ci/xpu/xpu_ci_start_container.sh`) :
XPU_KERNEL_CACHE_DIR 显式覆盖时原样使用、不做剪枝; 否则通过 `docker image inspect --format '{{.Id}}'` 取镜像 ID 的 12 位短 hash, 拼出 `kernel-cache-gpu${ZE_AFFINITY_MASK}-${IMG_ID_SHORT}` 目录; inspect 失败时 fallback 到 `kernel-cache-gpu${ZE_AFFINITY_MASK}-unversioned-$$` 一次性目录并打印警告。这样镜像内容变化即换新缓存, 避免 stale .so 被 dlopen。
2. 旧缓存清理与超限重置统一改用 busybox (同一脚本) : 用 `shopt -s nullglob` 收集同 GPU 下其他镜像 ID 的兄弟缓存目录及 legacy 无版本目录, 通过 `docker run --rm -v ${CACHE_ROOT}:/c busybox:latest rm -rf ...` 清理 root 所有者文件 (与 workspace 所有权重置同模式), `|| true` 兜底; 容量超过 XPU_KERNEL_CACHE_MAX_MB (默认 5120 MiB) 时, 也将原 runner 级 `rm -rf` 改为同一个 busybox helper 清理子目录。
3. 放宽 stage-b 测试窗口 (`.github/workflows/pr-test-xpu.yml`) : Run stage-b tests 步骤 `timeout-minutes` 从 60 提升到 120, 避免 action 墙切断 `test_intel_xpu_backend.py` 的重试和 `test_xpu_graph.py` 的长时间执行。
4. 修复 GDN kernel 哨兵越界 (`python/sglang/srt/hardware_backend/xpu/kernels/fla/chunk_delta_h.py`) : 在 `chunk_gated_delta_rule_fwd_kernel_h_blockdim64_k_loop` 中读取

initial_state_indices 后计算 valid_state = index >= 0, Phase 1/Phase 2 的 h 加载分支以及 INPLACE_UPDATE 写回均以 valid_state 守卫, padded 行直接使用零块, 不再让 -1 哨兵进入指针算术。

5. 测试配套: 本 PR 未新增测试文件; kernel 修复的验证依赖 PR #33431 引入的 test_padded_state_index_is_skipped (该测试在 XPU 上原本确定性失败), CI 整体效果通过 XPU stage-b 全量回归验证。

关键文件:

- scripts/ci/xpu/xpu_ci_start_container.sh (模块 CI 缓存; 类别 infra; 类型 infrastructure) : 核心变更文件: 缓存键控从 gpu-mask 改为 gpu-mask + 镜像内容 ID, 引入 busybox 清理 root 所有的旧缓存, 并保留显式覆盖、fallback 与容量超限重置逻辑。
- python/sglang/srt/hardware_backend/xpu/kernels/fla/chunk_delta_h.py (模块 XPU 内核; 类别 source; 类型 core-logic; 符号 chunk_gated_delta_rule_fwd_kernel_h_blockdim64_k_loop) : 运行时 kernel 修复: 为 GDN chunked kernel 增加 valid_state 守卫, 避免 -1 padding 哨兵进入指针算术导致 XPU 上读写 state pool 之前的内存; 是 PR #33431 测试在 XPU 上确定性失败的根因修复。
- .github/workflows/pr-test-xpu.yml (模块 工作流; 类别 infra; 类型 infrastructure) : 将 stage-b 测试 action 超时从 60 分钟提高到 120 分钟, 避免测试重试或挂起时被 wall 切掉 (曾切断 test_intel_xpu_backend.py 重试与 test_xpu_graph.py 的长时间执行)。

关键符号: chunk_gated_delta_rule_fwd_kernel_h_blockdim64_k_loop

关键源码片段

scripts/ci/xpu/xpu_ci_start_container.sh

核心变更文件: 缓存键控从 gpu-mask 改为 gpu-mask + 镜像内容 ID, 引入 busybox 清理 root 所有的旧缓存, 并保留显式覆盖、fallback 与容量超限重置逻辑。

```
# 显式覆盖优先: 使用 XPU_KERNEL_CACHE_DIR 原样路径, 不做剪枝
if [[ -n "${XPU_KERNEL_CACHE_DIR:-}" ]]; then
    XPU_KERNEL_CACHE_HOST="${XPU_KERNEL_CACHE_DIR}"
else
    # `ll IMG_ID_SHORT=""` 保证 pipefail 下 inspect 失败不会杀死脚本
    IMG_ID_SHORT=$(docker image inspect --format '{{.Id}}' "${IMAGE}" 2>/dev/null \
        | sed 's/^sha256:/' | cut -c1-12) || IMG_ID_SHORT=""
    CACHE_ROOT="${HOME}/.cache/sglang-xpu-ci"
    GPU_KEY="gpu${ZE_AFFINITY_MASK:-shared}"
    if [[ -n "${IMG_ID_SHORT}" ]]; then
        # 缓存目录包含镜像内容 ID: 镜像重建后自动换新缓存, 避免 dlopen 旧 .so
        XPU_KERNEL_CACHE_HOST="${CACHE_ROOT}/kernel-cache-${GPU_KEY}-${IMG_ID_SHORT}"
        # 清理同 GPU 下其他镜像 ID 的兄弟缓存及旧版无版本目录 (文件为容器 root 所有)
        shopt -s nullglob
        stale_siblings=("${CACHE_ROOT}/kernel-cache-${GPU_KEY}-*" "${CACHE_ROOT}/kernel-cache-${GPU_KEY}")
        shopt -u nullglob
        for sibling in "${stale_siblings[@]}; do
            [[ -d "${sibling}" ]] || continue
```

```

[[ "${sibling}" == "${XPU_KERNEL_CACHE_HOST}" ]] && continue
echo "Pruning stale kernel cache: ${sibling}"
docker run --rm -v "${CACHE_ROOT}:/c" busybox:latest \
    rm -rf "/c/$(basename "${sibling}")" || true
done
else
    # inspect 失败时使用一次性目录，避免读到被污染的旧缓存
    echo "Warning: could not resolve image ID for ${IMAGE}; using throwaway cache." >&2
    XPU_KERNEL_CACHE_HOST="${CACHE_ROOT}/kernel-cache-${GPU_KEY}-unversioned-$$"
fi
fi

```

python/sglang/srt/hardware_backend/xpu/kernels/fla/chunk_delta_h.py

运行时 kernel 修复：为 GDN chunked kernel 增加 valid_state 守卫，避免 -1 padding 哨兵进入指针算术导致 XPU 上读写 state pool 之前的内存；是 PR #33431 测试在 XPU 上确定性失败的根因修复。

```

# Padded 行携带 -1 哨兵值；若不守卫，哨兵会进入指针运算，
# 让地址落到 state pool 之前，导致越界读写在 XPU 上改变状态池。
valid_state = index >= 0
h0 = initial_state + index * stride_h
ht = initial_state + index * stride_h
if USE_INITIAL_STATE:
    h0 = h0 + i_h * V * K
if INPLACE_UPDATE:
    ht = ht + i_h * V * K

# 主递推循环：时间作为外层循环
for i_t in range(NT):
    # Phase 1: 计算 v_new = u - sum_k(w_k @ h_k^T)
    b_v_corr = tl.zeros([BT, BV], dtype=tl.float32)
    for k_blk in range(0, K, 64):
        if i_t == 0:
            if USE_INITIAL_STATE and valid_state:
                p_hs = tl.make_block_ptr(
                    h0, (V, K), (K, 1), (i_v * BV, k_blk), (BV, 64), (1, 0)
                )
                b_h = tl.load(p_hs, boundary_check=(0, 1)).to(tl.float32)
            else:
                # 无效行 (padded) 直接置零，不触碰初始状态池
                b_h = tl.zeros([BV, 64], dtype=tl.float32)
        elif valid_state:
            p_hs = tl.make_block_ptr(
                ht, (V, K), (K, 1), (i_v * BV, k_blk), (BV, 64), (1, 0)
            )
            b_h = tl.load(p_hs, boundary_check=(0, 1)).to(tl.float32)
        else:
            b_h = tl.zeros([BV, 64], dtype=tl.float32)

```

```

# 存储更新前的 h 到输出
p_ho = tl.make_block_ptr(
    h + i_t * stride_h,
    (V, K),
    (K, 1),
    (i_v * BV, k_blk),
    (BV, 64),
    (1, 0),
)
tl.store(p_ho, b_h.to(p_ho.dtype.element_ty), boundary_check=(0, 1))

# 累加 w_k @ h_k^T 修正项
b_w = w_desc.load([i_t * BT, k_blk])
b_v_corr += tl.dot(b_w, tl.trans(b_h).to(b_w.dtype))
# 后续 gating 与 Phase 2 更新逻辑与 Phase 1 对称，同样受 valid_state 守卫

```

评论区精华

本 PR 无 review 评论（comments 与 review comments 均为 0），两位 reviewer [pramodkumar-habanalabs](#) 与 [mingfeima](#) 直接 approve。有价值的决策讨论体现在 6 个 commit 的演进中：

- commit 5011ff6 指出：在 set -euo pipefail 下，docker image inspect 失败会以 rc=1 穿过管道直接杀死脚本，导致 fallback 分支成为死代码、step 静默退出 1；修复方式是在管道后追加 || IMG_ID_SHORT="" 兜底。
- commit 73b3009 记录：60 分钟 action 墙切断了 test_intel_xpu_backend.py 的完整重试（1800s 首测 + 91s 重试），且 test_xpu_graph.py 在测试 10/11 开始挂起，因此将超时提到 120 分钟。
- commit 6340656 记录：test_padded_state_index_is_skipped[all_padded] 在 XPU 上让 GDN pool 发生变更，必须加 -1 哨兵守卫。
- image-id fallback 在 pipefail 下不可达 (correctness): 在管道后追加 || IMG_ID_SHORT="" 兜底，保证 inspect 失败时 fallback 分支可达。
- stage-b 60 分钟 wall 切掉测试 (performance): 将 Run stage-b tests 的 timeout-minutes 从 60 提升到 120。

风险与影响

- 风险：
 1. XPU kernel 修复缺独立测试文件：chunk_delta_h.py 的控制流改动无新增测试，依赖 PR #33431 的 test_padded_state_index_is_skipped 回归；若该测试未覆盖所有分支组合（如 USE_INITIAL_STATE 与 valid_state 的交叉），仍存在回归盲区。
 2. 缓存清理依赖 busybox 镜像：docker run busybox:latest 需要 runner 能拉取镜像且 docker 可用；失败时虽有 || true 兜底，但旧缓存不会被清理，长期可能堆积磁盘。
 3. 镜像重建后全量冷编译：镜像 ID 变化意味着所有 XPU 机器首次运行都要全量 JIT 编译，stage-b 超时虽已放宽到 120 分钟，但极端情况下仍有超时风险；docker image

inspect 失败时使用一次性目录，若持续失败则每次都是冷缓存。

4. shell 管道兼容性: `set -euo pipefail` 与 `docker image inspect | sed | cut` 管道交互曾导致 fallback 死代码 bug，虽然已修复，但后续任何管道改动都需注意 `pipefail` 语义。
5. 12 位镜像 ID 截断碰撞: sha256 截断 12 位理论上存在极低碰撞概率，作为 CI 缓存键可接受，但需知晓该假设。

- 影响:

1. XPU CI 稳定性: 修复镜像重建后所有 XPU job 因 `dlopen` 旧 `.so` 必挂的问题; 镜像不变期间缓存复用, 镜像变更时自动换新并清理旧缓存, 磁盘占用受 5 GiB cap 约束。
2. 运行时用户: 非 XPU 后端不受影响; XPU 上 GDN (gated delta rule) chunked 前向在 padded 批次下的行为被纠正, 避免状态池被越界读写导致的结果错误或潜在崩溃。
3. 团队维护成本: XPU CI 缓存语义更复杂 (镜像 ID 维度), 维护者需理解 XPU_KERNEL_CACHE_DIR 覆盖、pruning 与 fallback 的优先级; stage-b 窗口翻倍意味着 CI 资源占用上限提高。 - 风险标记: XPU 后端 kernel 守卫修复无独立测试文件, 缓存清理依赖 busybox 镜像可拉取, 镜像重建后全量冷编译, 超时风险仍存, shell 管道 `pipefail` 兼容性 (曾有死代码 bug)

关联脉络

- PR #33431 PR #33431 (commit 提及, 引入 `test_padded_state_index_is_skipped`): commit 6340656 明确提到该 PR 新增的 `test_padded_state_index_is_skipped[all_padded]` 在 XPU 上确定性失败, 驱动了 `chunk_delta_h.py` 的 -1 哨兵守卫修复。