

PR #30394 完整报告

sgl-project/sglang

fix: make automatic NUMA binding configurable

合并时间: 2026-08-13 08:40

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30394>

执行摘要

- 一句话: 恢复自动 NUMA 绑定开关, 支持通过环境变量禁用
- 推荐动作: 值得快速精读, 改动小而目标明确, 是“配置项声明与实现失同步”的经典修复案例。重点关注三点: 一是默认值 `false` -> `true` 背后的行为保持推理 (关联 PR#19452); 二是门控位置放在显式 `--numa-node` 判断之后、NUMA 探测之前的优先级设计; 三是测试对 `SGLANG_NUMA_BIND_V2` 正交性的 `subTest` 验证方式。

功能与动机

PR body 明确指出 `SGLANG_AUTO_NUMA_BIND` 变量 "remained declared and documented ... but its gate was accidentally dropped during the automatic NUMA configuration refactor, leaving the variable ineffective", 即环境变量和文档都存在, 但控制逻辑在重构中丢失, 用户即使设置 `=0` 也无法真正禁用自动 NUMA 绑定。作者在 issue 评论中进一步说明, PR#19452 起默认行为已变为自动绑定, 本 PR 需要把默认值改为 `true` 才能忠实保持该行为。

实现拆解

变更入口在启动路径的 NUMA 解析函数 `get_numa_node_if_available` (`python/sglang/srt/utils/numa_utils.py`), 配套环境变量定义、文档与测试同步更新, 具体拆解如下:

1. 校准环境变量默认值 (`python/sglang/srt/envron.py`): 将 `SGLANG_AUTO_NUMA_BIND` 默认值由 `EnvBool(False)` 改为 `EnvBool(True)`, 与重构后实际的“未指定参数时自动 NUMA 绑定”行为对齐, 保证显式未配置时行为不变。
2. 恢复环境变量门控 (`python/sglang/srt/utils/numa_utils.py`): 在 `get_numa_node_if_available` 中、检查 `server_args.numa_node` 之后、NUMA 可用性探测之前插入 `if not envs.SGLANG_AUTO_NUMA_BIND.get(): return None`。这样 `SGLANG_AUTO_NUMA_BIND=0` 时直接跳过 `_is_numa_available` 与 `_query_numa_node_for_gpu` 的探测路径, worker 保持不绑定。显式 `--numa-node` 的优先级不受影响。
3. 补齐单元测试 (`test/registered/utils/test_numa_utils.py`): 新增 `test_auto_numa_bind_enabled_by_default` (验证默认开启)、`test_returns_explicit_numa_node_when_auto_bind_disabled` (验证禁用时显式节点仍生

效)、`test_auto_bind_disabled_skips_numa_detection` (验证禁用时跳过 NUMA 探测, 并用 `subTest` 覆盖 `SGLANG_NUMA_BIND_V2` 两种取值证明两个变量正交); 既有自动探测用例补充 `SGLANG_AUTO_NUMA_BIND=1` 环境设定。测试注册到 CPU CI `base-a-test-cpu` 和 CUDA CI `4-gpu-gb300 / 4-gpu-b200`。

- 更新文档 (`docs/docs/references/environment_variables.mdx`): 重写 `SGLANG_AUTO_NUMA_BIND` 说明, 明确“未指定 `--numa-node` 时自动检测 GPU 所在 NUMA 节点并绑定, 设为 `false` 则不绑定, 显式 `--numa-node` 优先”; 同时澄清 `SGLANG_NUMA_BIND_V2` 只选择实现 (`pre-launch numactl wrapper` 或 `worker` 内绑定)、不控制开关, 避免两个变量职责混淆。

关键文件:

- `python/sglang/srt/utils/numa_utils.py` (模块 NUMA 配置; 类别 source; 类型 core-logic; 符号 `get_numa_node_if_available`): 核心控制流变更: 在 `get_numa_node_if_available` 中恢复 `envs.SGLANG_AUTO_NUMA_BIND` 门控, 决定启动路径是否自动探测并绑定 NUMA 节点。
- `python/sglang/srt/envron.py` (模块 环境配置; 类别 source; 类型 configuration; 符号 `SGLANG_AUTO_NUMA_BIND`): 环境变量默认值修复的源头: `SGLANG_AUTO_NUMA_BIND` 默认值从 `false` 改为 `true`, 与 PR#19452 之后的实际自动绑定行为对齐。
- `test/registered/utils/test_numa_utils.py` (模块 NUMA 测试; 类别 test; 类型 test-coverage; 符号 `test_auto_numa_bind_enabled_by_default`, `test_returns_explicit_numa_node_when_auto_bind_disabled`, `test_auto_bind_disabled_skips_numa_detection`): 新增 3 个测试用例覆盖默认启用、禁用时显式节点优先、禁用时跳过 NUMA 探测三态, 是本次修复正确性的主要验证载体。
- `docs/docs/references/environment_variables.mdx` (模块 文档; 类别 other; 类型 documentation): 同步更新 NUMA 相关环境变量的语义与默认值表格, 澄清 `SGLANG_AUTO_NUMA_BIND` 与 `SGLANG_NUMA_BIND_V2` 的职责边界。

关键符号: `get_numa_node_if_available`

关键源码片段

`python/sglang/srt/utils/numa_utils.py`

核心控制流变更: 在 `get_numa_node_if_available` 中恢复 `envs.SGLANG_AUTO_NUMA_BIND` 门控, 决定启动路径是否自动探测并绑定 NUMA 节点。

```
def get_numa_node_if_available(server_args: ServerArgs, gpu_id: int) -> Optional[int]:
    """
    返回给定 GPU id 对应的 NUMA 节点; 若 server_args 未显式配置,
    则根据 SGLANG_AUTO_NUMA_BIND 决定是否自动探测并绑定。
    """
    # 优先级 1: 显式 --numa-node 永远优先, 不经过环境变量门控
    if server_args.numa_node is not None:
        return server_args.numa_node[gpu_id]

    # 优先级 2: 用户显式禁用自动绑定 (SGLANG_AUTO_NUMA_BIND=0) 时,
```

```

# 跳过 NUMA 可用性探测与 GPU -> NUMA 节点查询，保持 worker 不绑定
if not envs.SGLANG_AUTO_NUMA_BIND.get():
    return None

# 优先级 3: 默认路径，自动探测 GPU 所在 NUMA 节点
if _is_numa_available():
    queried_numa_node = _query_numa_node_for_gpu(gpu_id)
    if len(queried_numa_node) == 0:
        return None
    if len(queried_numa_node) > 1:
        # 单 GPU 可能对应多个 NUMA 节点，当前取第一个；
        # 尚无硬件配置出现多于一个节点，因此仅告警不报错
        logger.warning(
            f"Multiple NUMA nodes found for GPU {gpu_id}: {queried_numa_node}. Using the first one."
        )
    return queried_numa_node[0]
return None

```

test/registered/utils/test_numa_utils.py

新增 3 个测试用例覆盖默认启用、禁用时显式节点优先、禁用时跳过 NUMA 探测三态，是本次修复正确性的主要验证载体。

```

class TestGetNumaNodeIfAvailable(unittest.TestCase):
    def _make_server_args(self, numa_node=None):
        args = MagicMock()
        args.numa_node = numa_node
        return args

# 默认行为：未显式设置环境变量时，自动绑定处于开启状态
def test_auto_numa_bind_enabled_by_default(self):
    with patch.dict(os.environ, {}, clear=True):
        self.assertTrue(envs.SGLANG_AUTO_NUMA_BIND.get())

# 禁用自动绑定后，显式 --numa-node 仍然优先
@patch.dict(os.environ, {"SGLANG_AUTO_NUMA_BIND": "0"})
def test_returns_explicit_numa_node_when_auto_bind_disabled(self):
    args = self._make_server_args(numa_node=[2, 3, 0, 1])
    self.assertEqual(get_numa_node_if_available(args, 0), 2)
    self.assertEqual(get_numa_node_if_available(args, 3), 1)

# 禁用自动绑定时，跳过 NUMA 可用性与 GPU 节点探测
@patch("sglang.srt.utils.numa_utils._query_numa_node_for_gpu")
@patch("sglang.srt.utils.numa_utils._is_numa_available")
def test_auto_bind_disabled_skips_numa_detection(self, mock_avail, mock_query):
    args = self._make_server_args(numa_node=None)
    # 同时验证 SGLANG_NUMA_BIND_V2 两种取值下开关均生效
    for bind_v2 in ("0", "1"):
        with self.subTest(bind_v2=bind_v2), patch.dict(

```

```
os.environ,
{"SGLANG_AUTO_NUMA_BIND": "0", "SGLANG_NUMA_BIND_V2": bind_v2},
):
    self.assertIsNone(get_numa_node_if_available(args, 0))
mock_avail.assert_not_called()
mock_query.assert_not_called()
```

评论区精华

该 PR 没有实质性 review 争论，合并者 Fridge003 直接批准。关键澄清来自作者 lluki 在 issue 评论中的说明："Starting with 19452, the default behavior became to NUMA pin if no options are given. My PR keeps that behavior intact: Pin, if no option is given. This is why we have to change the default of SGLANG_AUTO_NUMA_BIND to true." 这解释了默认值看似翻转、实为修复“声明与实际行为不一致”的设计决策。合并前由 maintainer 触发了一次针对 `test_numa_utils.py` 的 CI 重跑，`4-gpu-gb300` 与 `4-gpu-b200` 均通过；`gemini-code-assist` 自动 review 无实质反馈。

- 暂无高价值评论线程

风险与影响

- 风险：
 - 行为变化风险：对从未设置过该变量的用户完全无感知；但凡是此前设置了 `SGLANG_AUTO_NUMA_BIND=0` 的用户，修复后会自动绑定真正失效，可能带来预期的性能变化或意外回归。
 - 启动路径变更：改动位于 `get_numa_node_if_available`（`python/sglang/srt/utils/numa_utils.py`），这是每个 GPU worker 启动时都会经过的 NUMA 决策路径，属于启动关键路径，但分值路径清晰且被新测试覆盖。
 - 兼容性：`SGLANG_NUMA_BIND_V2` 与 `SGLANG_AUTO_NUMA_BIND` 职责正交，前者的实现选择语义不受影响；测试专门覆盖了 `SGLANG_NUMA_BIND_V2=0/1` 两种组合。
 - 测试覆盖：新增测试覆盖了默认启用、显式禁用、显式 `--numa-node` 优先三态，但未覆盖“禁用 + 非 CUDA 环境”或“禁用 + NUMA 不可用”的组合，这两条路径逻辑上由短路返回保证，风险很低。
 - 影响：影响范围覆盖所有通过环境变量管理 NUMA 绑定的 SGLang 多 GPU 部署：恢复了已声明配置项的实际功能，默认行为保持不变，不需要用户修改现有启动命令；对文档读者而言，两个 NUMA 相关环境变量的职责边界（开关 vs 实现选择）更加清晰。对团队而言，这是一次低成本、低风险的配置一致性修复，且补齐了回归测试，防止后续重构再次丢失门控逻辑。
- 风险标记：配置项功能修复，启动路径变更，默认值调整，有测试覆盖

关联脉络

- PR #19452 Automatic NUMA configuration refactor（作者在 issue 评论中提及）：该 PR 将默认行为改为未指定参数时自动 NUMA 绑定，但漏掉了 `SGLANG_AUTO_NUMA_BIND` 门控逻辑；本 PR 是其功能收尾修复，默认值 `true` 正是为

保持 19452 后的行为而设定。