

PR #36205 完整报告

sgl-project/sglang

Gate the idle-loop tree-cache sanity check behind a default-off env

合并时间: 2026-08-30 00:10

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36205>

执行摘要

- 一句话: 空闲循环树缓存深度校验默认关闭, 修复 DP 组调度卡死
- 推荐动作: 值得精读。代码量虽小, 却包含两个可复用设计: 一是用 EnvField 的 callable default 实现「生产默认关、CI 默认开、显式覆盖优先」的三态配置语义, 让调试仪器默认不进生产路径同时不牺牲 CI 回归; 二是测试通过 contextmanager 清理进程环境变量来稳定默认值断言, 是环境耦合测试的典型解法。对调度器与缓存团队, 建议同时关注 sanity_check 自身性能 (TODO(hzh)) 与文档同步。

功能与动机

PR body 描述了确定性复现的生产事故: Scheduler.on_idle 在每个空闲迭代无条件调用 _check_tree_cache() → tree_cache.sanity_check(), 而该方法为纯 Python 全树遍历 (自带 TODO(hzh) 注明高延迟), 大树单次可达数十秒。在 8xGPU DeepSeek-V4 类部署 (tp4/dp4, --enable-dp-attention、hybrid SWA) 上, 请求排空的 rank 进入空闲后不断重启全树 walk, 其余 rank 阻塞在 broadcast_pyobj (recv_requests) 与 MoE a2a 集合通信上, 出现 GPUs 0%、调度器约 190% CPU 的永久楔死。py-spy 多次抓取确认 walk 每轮 idle 迭代重新开始, 组内无法推进。作者结论是「The full-tree walk is debug instrumentation, so make it opt-in」, 即把调试仪器从生产路径中分离出去。

实现拆解

1. 新增环境开关 (python/sglang/srt/envron.py): 定义 _default_tree_cache_sanity_check() 延迟默认值函数, 返回 envs.SGLANG_IS_IN_CI.get(); 声明 SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK = EnvBool(_default_tree_cache_sanity_check)。利用 EnvField 的 callable default 机制 (_resolve_default 仅在该变量未被显式设置时才求值默认值), 实现「生产 (非 CI) 默认关、CI 默认开、显式设置永远优先」的三态语义, 无需 CI 配置文件显式注入变量。
2. 在调用点加 gate (python/sglang/srt/managers/scheduler_components/invariant_checker.py): _check_tree_cache() 开头先判断 envs.SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK.get(), 为 False 直接 return; 原有 tree cache 类型 + hybrid SWA/SSM 支持判定与 sanity_check 调用保持不变。廉价的空间池与 req-pool 泄漏检查 (_check_full_pool / _check_swa_pool / _check_mamba_pool) 不在 gate 内, 仍每轮执行。
3. 新增单元测试 (test/registered/unit/managers/scheduler_components/test_invariant_checker.py): 用 MagicMock 构造 SchedulerInvariantChecker, 覆盖 4 个场景——非

CI 默认关闭、CI 默认开启、CI 中显式关闭、非 CI 显式开启；通过 `_without_explicit_sanity_check_setting()` contextmanager 在断言默认值前清掉进程环境里的显式设置，解决 Codex 指出的环境变量泄漏问题。

4. 设计演进：第一版是 `EnvBool(False)` 纯默认关闭，review 中 `ispobock` 与 `hzh0425` 提出「至少 CI 保留」后，由 `hzh0425` 的 commit “run sanity check in ci” 改为与 `SGLANG_IS_IN_CI` 联动的延迟默认值，兼顾生产止血与 CI 回归。

关键文件：

- `python/sglang/srt/envron.py`（模块 环境配置；类别 source；类型 core-logic；符号 `_default_tree_cache_sanity_check`, `SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK`）：定义开关语义的核心文件：新增 `SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK` 与延迟默认值函数 `_default_tree_cache_sanity_check`，实现生产关、CI 开、显式优先的三态配置。
- `python/sglang/srt/managers/scheduler_components/invariant_checker.py`（模块 调度器；类别 source；类型 core-logic；符号 `_check_tree_cache`）：生产路径的实际变更落点：在 `_check_tree_cache()` 入口加短路 gate，是解除 DP 组 livelock 的关键一行。
- `test/registered/unit/managers/scheduler_components/test_invariant_checker.py`（模块 单元测试；类别 test；类型 test-coverage；符号 `TestCheckTreeCacheGate`, `_without_explicit_sanity_check_setting`, `_make_checker`, `test_disabled_by_default`）：新增 4 个场景的 gate 测试，并示范如何通过 contextmanager 隔离进程环境变量以稳定默认值断言。

关键符号：`_default_tree_cache_sanity_check`, `_check_tree_cache`, `TestCheckTreeCacheGate`, `_without_explicit_sanity_check_setting`

关键源码片段

`python/sglang/srt/managers/scheduler_components/invariant_checker.py`

生产路径的实际变更落点：在 `_check_tree_cache()` 入口加短路 gate，是解除 DP 组 livelock 的关键一行。

```
def _check_tree_cache(self):
    # 全树一致性校验是纯 Python 调试仪器，每个空闲迭代都会命中；
    # 大树（数千条序列）单次遍历可达数十秒，DP 场景会拖死整个组，
    # 因此默认仅 CI / 显式调试开启，生产路径直接短路返回。
    if not envs.SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK.get():
        return

    if (
        self.tree_cache.is_tree_cache()
        and (self.is_hybrid_swa and self.tree_cache.supports_swa())
        or (self.is_hybrid_ssm and self.tree_cache.supports_mamba())
    ):
        self.tree_cache.sanity_check()
```

test/registered/unit/managers/scheduler_components/test_invariant_checker.py

新增 4 个场景的 gate 测试，并示范如何通过 contextmanager 隔离进程环境变量以稳定默认值断言。

```
class TestCheckTreeCacheGate(CustomTestCase):
    @contextmanager
    def _without_explicit_sanity_check_setting(self):
        # 从进程环境剔除显式设置，避免外层 CI / 调试运行环境已导出的
        # SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK 干扰默认值断言；
        # clear=False 仅清除该字段，其余环境变量保持不变。
        with patch.dict(os.environ, {}, clear=False):
            envs.SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK.clear()
            yield

    def test_disabled_by_default(self):
        # 非 CI 且未显式设置：默认应关闭，sanity_check 不得被调用。
        with (
            envs.SGLANG_IS_IN_CI.override(False),
            self._without_explicit_sanity_check_setting(),
        ):
            checker = self._make_checker()
            checker._check_tree_cache()
            checker.tree_cache.sanity_check.assert_not_called()

    def test_enabled_by_default_in_ci(self):
        # CI 且未显式覆盖：默认应开启，深度一致性回归仍需生效。
        with (
            envs.SGLANG_IS_IN_CI.override(True),
            self._without_explicit_sanity_check_setting(),
        ):
            checker = self._make_checker()
            checker._check_tree_cache()
            checker.tree_cache.sanity_check.assert_called_once()
```

评论区精华

核心交锋是默认值策略：

- ispobock 在 environ.py 上发问：「what do you think to turn off it by default? Maybe we need to keep it in CI at least?」
- hzh0425 表示赞同并点名作者：「yes, we should keep in ci at least @sshleifer」，随后追加「@sshleifer could you help improve this?」
- 最终以 commit “run sanity check in ci” 落地为 callable 默认值方案：非 CI 默认 False、CI 默认 True，显式设置覆盖。
- Codex bot 提出 P2：test_disabled_by_default 未隔离进程环境（若运行环境已导出 SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK=1，EnvField.get() 会读到继承值导致

assert_not_called() 失败)，最终通过 `_without_explicit_sanity_check_setting()` context manager 保存并清除该变量解决。

- hzh0425 对测试文件第 11 行 (DisaggregationMode 导入附近) 留言「This test is not necessary」，但最终合并版本保留了全部 4 个测试场景与相关导入，该意见未落地。
- 默认关闭的取舍与 CI 保留 (design): 改为 callable 默认值 `_default_tree_cache_sanity_check()`，非 CI 默认 False、CI 默认 True，显式设置优先。
- 测试需隔离进程环境变量 (Codex P2) (testing): 引入 `_without_explicit_sanity_check_setting()` contextmanager，用 `patch.dict + clear()` 清理后恢复。
- hzh0425 认为某处测试不必要 (question): 最终合并版本保留了全部 4 个测试场景与相关导入，该意见未落地。

风险与影响

- 风险:
 1. 生产深度校验丢失: 默认关闭后，大规模部署不再执行 `tree_cache.sanity_check()`，树结构回归 (节点计数、父子链、SWA 视图) 依赖 CI 兜底，而 CI 覆盖的树规模远小于生产，隐藏问题可能上线后才暴露。
 2. 求值时机耦合: callable 默认值在首次读取时求值 `SGLANG_IS_IN_CI`，若运行环境在启动后动态改变该变量，开关行为可能不一致；SGLANG 的 EnvBool 通常早期固定，风险有限。
 3. 显式优先级语义: 代码注释明确了「显式变量优先于 CI 默认」，但 PR 未勾选 documentation checklist，用户可能不知道这个开关的存在与语义。
 4. 根因未除: `sanity_check()` 本身的 $O(\text{节点数})$ 纯 Python 遍历仍在，只是默认不触发；后续新增调试校验需求时可能重蹈覆辙，建议后续将 `sanity_check` 改为稀疏 / 增量检查或编译优化。
 5. 测试环境耦合: 若外部 CI 全局导出 `SGLANG_ENABLE_TREE_CACHE_SANITY_CHECK=1`，`test_disabled_by_default` 已通过 helper 隔离；但并行执行环境下仍需注意环境变量串扰。
- 影响: 影响范围集中在调度器空闲路径与调试配置:
 - 用户 / 部署: DP attention + EP (tp4/dp4、hybrid SWA) 等会周期性整体空闲的部署直接受益，饱和 benchmark 后半段不再楔死；非 DP 部署的空闲开销也显著下降，且无需任何配置即生效。
 - CI: `SGLANG_IS_IN_CI` 为 True 的套件默认保持深度检查，一致性回归能力不丢失；显式设 False 可对特殊用例豁免。
 - 团队: 为调试仪器与生产路径分离提供了新模式 (延迟默认值 + 环境 gate)，后续同类检查 (如 `SGLANG_ENABLE_ASYNC_ASSERT`、`SGLANG_CHECK_KV_PAGE_INVARIANTS`) 可沿用同一套路；但文档未同步，需要后续补充。
 - 风险标记: 生产默认关闭深度校验，CI 默认开启，测试需隔离环境变量，根因未除 (`sanity_check` 仍为全量遍历)，文档未同步

关联脉络

- PR #37151 [Unified Cache Linker][3/N]: Add backend-independent linker core: 同属 unified cache / 基数树演进线, 被 gate 的 sanity_check 正是 unified_radix_cache / unified_cache_linker 的调试仪器。
- PR #37166 fix(staging): make empty staging rings reusable: 同为 DP/PD 场景调度卡死类修复, 与本 PR 同属调度器稳定性止损脉络。
- PR #37094 [mem_cache] Move req_pool_idx into ReqKvInfo: mem_cache / 调度器内存路径重构系列的一部分, 本 PR 的 gate 为这类调试校验提供可开关模式。