

PR #34186 完整报告

sgl-project/sglang

[CI] Key scheduled CUDA suites by runner_config instead of hand-written jobs

合并时间: 2026-08-10 07:44

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34186>

执行摘要

- 一句话: CUDA 夜测迁移至 runner_config 注册式调度, 统一走 _pr-test-stage.yml
- 推荐动作: 值得 CI 基础设施负责人精读: 该 PR 展示了如何通过 registry-keyed 注册把分散的手写调度收敛为单一执行路径, scheduled 输入作为 per-commit 与夜间行为差异的关键设计干净, token 隔离与超时推导的注释含实证依据。对一般功能开发者, 只需了解测试注册格式变更即可, 不影响业务代码。关注点建议放在迁移完整性和超时预算变化上, 可在合并后观察一个周期的 nightly 结果确认无静默丢失。

功能与动机

PR body 明确指出: "Replaces the hand-written nightly/weekly job list with registry-keyed stages, so scheduled suites run through the same _pr-test-stage.yml path as per-commit CI." 此前 nightly 工作流中每个 job 手写 runs-on、安装步骤、分区矩阵、超时参数, 与 per-commit CI 的 runner_configs 体系割裂, 测试若要上线一台新机型必须同时修改 workflow 与 suite 注册两处。改为 registry-keyed 后, 测试通过 register_cuda_ci 声明 runner_config 即可自动落入对应机器的夜间套件, workflow 文件不再需要按 job 维护。

实现拆解

1. 注册契约迁移: 批量改写测试文件中的 register_cuda_ci 调用, 从 suite="nightly-8-gpu-b200", nightly=True 形式改为 stage="nightly", runner_config="8-gpu-b200"。涉及 test/registered/ 下数十个文件 (如 test_dsa_glm52_cache_layer_split.py、test_custom_all_reduce.py、8-gpu-models/test_glm52_fp8.py 等), nightly 标识不再由 flag 表达, 而是由 stage 名称承载。
2. suite 命名与校验逻辑调整 (test/run_suite.py): NIGHTLY_SUITES 中 CUDA 分支从 19 个手写 suite 名缩减为 7 个 nightly-test-{runner_config} 形状的条目; filter_tests 的合法性校验从只查 NIGHTLY_SUITES 或 PER_COMMIT_SUITES 之一, 改为查三个字典的并集 (_valid_suites_by_backend()), 因为 CUDA 夜测 suite 仅凭名称选择、不再依赖 --nightly。
3. workflow 重构 (.github/workflows/nightly-test-nvidia.yml、weekly-test-nvidia.yml、_pr-test-stage.yml): 夜间工作流删除了约 550 行手写 job, 改为按 runner_config 动态调用 _pr-test-stage.yml; _pr-test-stage.yml 新增 scheduled 输入, 用于切换夜间行为: --timeout-from-est-time 逐文件超时、完整 jit kernel 测试网格 (

SGLANG_JIT_KERNEL_RUN_FULL_TESTS=1)、IS_H200 服务器启动上限放宽、metrics 收集上传、以及默认串行 shard (除非 full_parallel=true)。precision baseline 所需环境变量也在此步骤导出。

4. 超时推导 (python/sglang/test/ci/ci_utils.py) : 新增 derive_timeout_per_file(est_time) = max(est * 1.5, est + 1800), run_unittest_files 的 timeout_per_file 参数改为 Optional[float], 为 None 时按每个文件的 est_time 推导预算; run_suite.py 新增 --timeout-from-est-time 开关。
5. 配套清理: scripts/ci/utils/slash_command_handler.py 删除 _LEGACY_SUITE_TO_RUNNER_CONFIG 映射, 旧式单字符串 suite= 注册不再可通过 /rerun-test 调度, 错误消息引导重新注册; scripts/ci/stage_models_overrides.json 相应删除 12 个 legacy suite 的 label 映射; docs/docs/references/nightly_precision_regression.mdx 同步更新 token 变量名与 workflow 说明。

关键文件:

- .github/workflows/nightly-test-nvidia.yml (模块 夜测编排; 类别 infra; 类型 infrastructure) : 核心重构对象: 550 行手写 job 缩减为 180 行 registry-keyed 薄壳, 按 runner_config 动态复用 _pr-test-stage.yml, 是消除两套 CI 路径重复实现的关键。
- test/run_suite.py (模块 套件调度; 类别 test; 类型 test-coverage; 符号 NIGHTLY_SUITES, filter_tests, run_a_suite, main) : suite 注册契约的核心载体: NIGHTLY_SUITES 改为 nightly-test-{runner_config} 形状, filter_tests 校验逻辑从二分改为三字典并集, 并新增 --timeout-from-est-time 开关。
- python/sglang/test/ci/ci_utils.py (模块 CI 工具; 类别 test; 类型 test-coverage; 符号 derive_timeout_per_file, run_unittest_files) : 新增 derive_timeout_per_file 与 run_unittest_files 的 per-file 超时推导能力, 是夜间 suite 混合快慢测试时避免一刀切超时预算的关键支撑。
- python/sglang/test/precision_baseline_store.py (模块 基线存储; 类别 test; 类型 test-coverage; 符号 _store_token) : 精度基线存储的写 token 从 HF_TOKEN 系列隔离为独立环境变量 SGLANG_PRECISION_HF_TOKEN, 避免遮蔽 runner 的 gated-model 读 token, 属于安全相关的关键配套。
- scripts/ci/utils/slash_command_handler.py (模块 CI 命令; 类别 infra; 类型 infrastructure; 符号 _extract_legacy_suites, detect_suite) : 删除 _LEGACY_SUITE_TO_RUNNER_CONFIG 映射, 旧式单字符串 suite 注册不再可被 /rerun-test 调度, 是本次迁移的收尾动作, 决定了遗留注册项的可运维性。
- .github/workflows/_pr-test-stage.yml (模块 测试管线; 类别 infra; 类型 infrastructure) : 统一执行路径的承载者: 新增 scheduled、job_timeout_minutes 输入, 按 schedule 切换完整 jit 网格、IS_H200、HF_HUB 超时、metrics 收集与 precision baseline 环境导出。
- .github/workflows/weekly-test-nvidia.yml (模块 周测编排; 类别 infra; 类型 infrastructure) : 周测工作流同步迁移到 registry-keyed 模式, 通过与 nightly 相同的 check-changes + stage 调用结构验证该模式的通用性。

关键符号: derive_timeout_per_file, filter_tests, run_unittest_files, _store_token, detect_suite, _extract_legacy_suites

关键源码片段

test/run_suite.py

suite 注册契约的核心载体: NIGHTLY_SUITES 改为 nightly-test-{runner_config} 形状, filter_tests 校验逻辑从二分改为三字典并集, 并新增 --timeout-from-est-time 开关。

```
# test/run_suite.py
# CUDA 夜间套件不再按功能手写名字, 而是按 runner_config 组织:
# 测试通过 register_cuda_ci(stage="nightly", runner_config=...) 声明归属,
# stage 名称承载节奏, 不再需要 nightly=True flag。
def filter_tests(
    ci_tests: List[CIRegistry], hw: HWBackend, suite: str, nightly: bool = False
) -> List[CIRegistry]:
    ci_tests = [
        t
        for t in ci_tests
        if t.backend == hw and t.effective_suite == suite and t.nightly == nightly
    ]

    # 合法性校验需要三个字典的并集, 而不是只看 per-commit 或 nightly 半边:
    # CUDA nightly suite 直接按名称选取, 不依赖 --nightly flag。
    if suite not in _valid_suites_by_backend().get(hw, set()):
        print(f"Warning: Unknown suite {suite} for backend {hw.name}")

    enabled_tests = [t for t in ci_tests if t.disabled is None]
    skipped_tests = [t for t in ci_tests if t.disabled is not None]
    return enabled_tests, skipped_tests
```

python/sglang/test/ci/ci_utils.py

新增 derive_timeout_per_file 与 run_unittest_files 的 per-file 超时推导能力, 是夜间 suite 混合快慢测试时避免一刀切超时预算的关键支撑。

```
# python/sglang/test/ci/ci_utils.py
# 慢速方差在很大程度上是加性的 (冷 HF cache、慢的 server 启动),
# 单纯乘系数会在两端都欠配: test_encoder_dp 实际跑 200-426s,
# 却曾以 1.5x 预算 (765s) 超时到 1185s; test_lora_deepseek_v3_base_logprob_diff
# (est 1800) 恰好落在 1.5 * est 上。因此每个文件在比例预算之上
# 再叠加同一份绝对松弛。
DERIVED_TIMEOUT_SLACK = 1800.0
DERIVED_TIMEOUT_FACTOR = 1.5

def derive_timeout_per_file(est_time: float) -> float:
    """根据单个文件的 est_time 推导超时上限, 取比例与绝对两者的较大值。"""
    est = float(est_time)
    return max(est * DERIVED_TIMEOUT_FACTOR, est + DERIVED_TIMEOUT_SLACK)
```

评论区精华

该 PR 没有实质 review 评论 (0 条 review comments; 2 条 issue comments 分别为 Mintlify 预览机器人通知和作者触发的 `/tag-and-rerun-ci`)。有价值的讨论内嵌在代码注释与提交演进中:

1) `ci_utils.py` 注释解释了超时公式的动机——"Slow-run variance is largely additive (cold HF cache, slow server launch), so the multiplier alone under-provisions at both ends", 并给出 `test_encoder_dp` 曾以 1.5x 预算 (765s) 实际耗时超过 1185s 的实证, 因此采用比例加绝对松弛的 `max(est*1.5, est+1800)` 组合; 2) `precision_baseline_store.py` 的 `_store_token` docstring 说明 token 隔离理由——"Deliberately not HF_TOKEN: that name already carries the runner's gated-model read token, so writing the store token there would shadow it and turn every gated model on the job into a 401"; 3) 提交 `revert gpu idle wait; fix stale suite name and --nightly help` 与 `restore IS_H200 and HF_HUB timeouts; widen derived timeout; fix metrics needs` 显示作者在自测中对策略做了多轮收敛 (如放宽推导超时、恢复 H200 启动上限与 HF_HUB 超时)。

- 超时推导公式的设计动机 (design): 采用 `max(est * 1.5, est + 1800)` 组合, 并让 `run_unittest_files` 在 `timeout_per_file=None` 时按每个文件自己的 `est_time` 推导预算; 后续提交 `widen derived timeout` 进一步放宽。
- precision 基线 token 与 gated-model 读 token 的隔离 (security): 新增独立环境变量 `SGLANG_PRECISION_HF_TOKEN`, workflow 导出步骤、`HfStoreConfig.from_env` 报错信息与文档全部同步切换。
- legacy suite 的 `/rerun-test` 可调度性回退 (design): 接受该回退: 所有可调度的 CUDA suite (`per-commit` 与 `scheduled`) 统一走 `runner_configs.yml` 单一来源, 遗留注册项降级为非可调度并提示迁移。
- nightly 与 `per-commit` 行为差异的开关设计 (design): 以 `scheduled: true` 作为统一开关, 配套 `job_timeout_minutes`、`run_timeout_minutes` 区分 job 级与 run 级超时, 避免在 `per-commit` 路径上引入夜间副作用。

风险与影响

- 风险: 1) 测试静默丢失风险: 94 个文件的批量迁移中, 若某个 `register_cuda_ci` 的 `stage/runner_config` 与 `run_suite.py` 中 `NIGHTLY_SUITES` 条目不匹配, 测试将得不到合法 suite 校验保护 (CUDA 之外的 backend 仍被 `_SUITE_CHECKED_BACKENDS` 排除在校验外), 可能静默不跑; 2) `--nightly` 语义变化: CUDA 夜测 suite 改为按名称选取, `--nightly` flag 仅对 AMD/CPU/NPU 生效, 旧脚本若沿用 `--nightly` + 新 suite 名组合可能选不到测试; 3) `/rerun-test` 能力回退: 删除 `_LEGACY_SUITE_TO_RUNNER_CONFIG` 后, 尚未迁移的 legacy suite (如 GB300 系列、部分 AMD) 无法再通过 `slash` 命令单独重跑, 排障效率下降; 4) 超时策略变化: `derive_timeout_per_file` 对短测试 (`est < 3600s`) 会给到明显更大的预算 (`est+1800`), 可能延长失败反馈时间, 而对 `est=0` 的测试 (如 `test_custom_all_reduce` 夜测注册 `est_time=110`) 则相对安全; 长测试 (如 `test_glm52_fp8` 的 `est_time=2880`) 所得预算低于旧版 `--timeout-per-file 18000`, 存在超时风险; 5) 令牌环境变量切换: precision 基线从 `HF_TOKEN_PRECISION_STORE/HF_TOKEN` 切换到 `SGLANG_PRECISION_HF_TOKEN`, 若 `_pr-test-stage.yml` 的导出步骤与 `_store_token` 读取不一致 (如 `secrets` 未注入), 基线读写会立即失败。

- 影响：影响范围集中在 CI 基础设施：所有 CUDA nightly/weekly 测试的调度路径（约 40+ 个测试文件、7 个 runner_config 机器池）从手写 workflow 迁移到统一 stage 管线，新增测试只需一次 register_cuda_ci 注册即可自动进入夜间队列，新增机器池只需在 runner_configs.yml 声明。对普通开发者，影响主要体现为测试注册 API 的格式变化（suite+nightly → stage+runner_config）；对 CI 维护者，消除了 nightly 与 per-commit 两套实现长期漂移的维护负担，并统一了分区计算、rust-ext 复用、metrics 上报等行为。团队协作上，后续调整夜间测试的机器选择、超时、并行度都只需改注册项或 _pr-test-stage.yml，不再需要编辑大型 workflow 文件。
- 风险标记：涉及 CI 核心调度路径，94 文件批量迁移存在静默丢失风险，legacy suite 失去 /rerun-test 能力，超时预算策略变化，token 环境变量切换

关联脉络

- PR #34147 [AMD] [CI] Register the DeepSeek-V4-Pro-DSpark MI35x nightly job so its suite actually runs: 同为夜间 CI 编排修复（AMD nightly job 从未真正运行），与本 PR 统一夜间调度路径的主题一致，验证了 registry 覆盖不足会导致测试静默不跑的问题。
- PR #34081 config: business code no longer reads the published ServerArgs: 同属 " 收敛到单一来源 " 的架构方向（配置读取统一到 runtime_context），与本 PR 将夜间 job 收敛到 runner_configs.yml 的单一事实来源理念一脉相承。
- PR #34133 config: derive the runner's DCP topology from its ParallelState: 同为 " 去掉重复推导、统一派生 " 的重构模式，与本 PR 消除 nightly/weekly 手写 job 重复实现的思路一致。