

PR #36699 完整报告

sgl-project/sglang

xpu: record per-model metrics to jsonl for nightly dashboard

合并时间: 2026-09-01 10:20

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36699>

执行摘要

- 一句话: XPU 夜间测试新增 per-model 指标 JSONL 记录与健康看板
- 推荐动作: 值得精读。核心看点: ① opt-in 零影响设计——env var 默认 None、全仓库无调用方, 配合 append-only 与吞错, 把“记录”与“决策”彻底分离, 这是 CI 可观测性改造的安全姿势; ② 双级记录 (model 级 rich records + file 级 fallback) 与 test_file 去重机制, 兼顾数据丰富度与覆盖率; ③ workflow 中直接内嵌 Python 渲染 dashboard 的做法, 优点是单文件自包含, 缺点是难测试。如果想复刻该模式, 建议至少补一条 jsonl schema 的自动化测试, 并统一 env var 的访问方式 (全部走 Envs descriptor)。

功能与动机

PR body 明确指出现状痛点: `xpu-ci-job-monitor.yml` 目前只在 suite 级别 (`nightly-xpu-1-gpu / -2-gpu / -4-gpu`) 上报, 而每个 suite 内部通过 `run_suite.py` 跑多个模型, monitor 只能看到 GitHub Actions 的聚合 job 状态——pass/fail, 无法知道“哪个模型回归、回归多少、是否跌破精度门槛”。本 PR 是四 PR 系列的最小切片, 目标是让监控降到 per-model 粒度, 为后续 dashboard 提供 ref / actual / status / duration 数据底座。

实现拆解

1. 注册 opt-in 环境变量: `python/sglang/srt/envron.py` 的 `Envs` 类新增 `SGLANG_TEST_METRICS_FILE = EnvStr(None)`, 挂在新 # CI reporting 分区下, 遵循仓库 env-var conventions skill (所有 `SGLANG_*` 变量必须走 descriptor 而非裸 `os.getenv`)。默认 `None` 保证全仓库无调用方时零行为变化。
2. model 级指标写入: `python/sglang/test/xpu/test_xpu_utils.py` 的 `write_results_to_github_step_summary` 在写完 Markdown 表格后追加调用新函数 `_append_metric_records`; 每个模型输出一行 JSON (`kind=model`), 包含 `accuracy`、阈值、`output_throughput`、`latency`、`num_prompts`、`num_threads`、`max_tokens`、`error` 与 `pass/fail` 状态, `test_file` 取自 `sys.argv[0]` 供渲染端去重; 同时 Step Summary 表头与每行新增 Prompts 列。
3. file 级兜底记录: `python/sglang/test/ci/ci_utils.py` 的 `run_unittest_files` 在 `timings` 输出之后、返回之前追加受保护的自动记录 (`kind=file`): 按测试文件记录 `pass/fail`、`duration` 与 `error`, 新增到 `run_suite.py` 的测试文件无需逐文件接线即可被 dashboard 覆盖。

4. workflow 上游接线: .github/workflows/nightly-test-intel.yml 为 1/2/4-GPU 三个 nightly 作业注入 SGLANG_TEST_METRICS_FILE=/sglang-checkout/nightly-xpu-{1,2,4}-gpu-metrics.jsonl, 并新增 if: always() 的 actions/upload-artifact@v4 上传步骤 (if-no-files-found: warn、retention 30 天), 失败作业也能留下记录。
5. 消费端看板: .github/workflows/xpu-ci-job-monitor.yml 新增两个 job——nightly-xpu-status-dashboard 按 job 聚合最近 24 小时成功率并输出 shields.io badge ($\geq 90\%$ healthy、 $\geq 70\%$ degraded、以下 critical 且 step 失败); nightly-xpu-per-model-report 用 gh run list 解析最新 completed 的 nightly run, 下载 metrics artifacts 后按 1x/2x/4x/8x 渲染 per-model 表格, 8x 为未来预留。
6. 测试与验证配套: 无新增自动化测试文件, PR 的 test plan 全为手动验证 (py_compile、设置 / 未设置 env var 的 dry-run、grep 确认无既有调用方); simple_eval_gsm8k_xpu_mixin.py 的 model_metrics 增加 num_prompts / num_threads / max_tokens 字段, 为 dashboard 提供样本量上下文。

关键文件:

- python/sglang/test/xpu/test_xpu_utils.py (模块 XPU 测试工具; 类别 test; 类型 test-coverage; 符号 _append_metric_records, write_results_to_github_step_summary) : 数据管道核心: 新增 _append_metric_records, 把每个模型的精度 / 阈值 / 吞吐 / 延迟 / 状态写成一行 JSON 追加到 SGLANG_TEST_METRICS_FILE; 同时 Step Summary 表格新增 Prompts 列。
- .github/workflows/xpu-ci-job-monitor.yml (模块 监控看板; 类别 infra; 类型 infrastructure; 符号 badge, health, sort_key, load) : 消费端: 新增 nightly-xpu-status-dashboard (fleet 健康看板, 90/70 阈值分级) 与 nightly-xpu-per-model-report (下载 metrics artifact 并渲染 1x/2x/4x/8x per-model 表格), 是整条数据管道的落点, 也是本 PR 行数最大的变更。
- python/sglang/srt/envron.py (模块 环境变量; 类别 source; 类型 configuration) : 按仓库 env-var conventions 注册 SGLANG_TEST_METRICS_FILE = EnvStr(None), 默认 None 是“未设置时零行为变化”承诺的根基; 该文件是全局环境变量注册中心, 后续所有平台复用此变量。
- python/sglang/test/ci/ci_utils.py (模块 测试编排; 类别 test; 类型 test-coverage; 符号 run_unittest_files) : 为未走 model 级写入器的测试文件提供 file 级兜底记录 (kind=file), 任何加入 run_suite.py 的测试自动被 dashboard 覆盖; 该文件影响所有套件的测试编排链路。
- .github/workflows/nightly-test-intel.yml (模块 workflow 配置; 类别 infra; 类型 infrastructure) : 数据管道上游接线: 为 1/2/4-GPU 三个 nightly 作业注入 SGLANG_TEST_METRICS_FILE 并新增 if: always() 的 artifact 上传步骤, 保证失败作业也能留下指标。
- python/sglang/test/xpu/simple_eval_gsm8k_xpu_mixin.py (模块 基准评测; 类别 test; 类型 test-coverage; 符号 test_gsm8k) : GSM8K mixin 的 model_metrics 补充 num_prompts / num_threads / max_tokens, 让 dashboard 能结合样本量解读 accuracy 分数 (200 个样本的 0.612 与 20 个样本的 0.612 统计意义不同)。

关键符号: `_append_metric_records`, `write_results_to_github_step_summary`,
`run_unittest_files`, `test_gsm8k`

关键源码片段

`python/sglang/test/xpu/test_xpu_utils.py`

数据管道核心: 新增 `_append_metric_records`, 把每个模型的精度 / 阈值 / 吞吐 / 延迟 / 状态写成一行 JSON 追加到 `SGLANG_TEST_METRICS_FILE`; 同时 Step Summary 表格新增 Prompts 列。

```
def _append_metric_records(results: dict) -> None:
    """把每个模型的指标追加为一行 JSON 到 SGLANG_TEST_METRICS_FILE (若已设置)。
```

```

    该文件由 xpu-ci-job-monitor.yml 的 nightly XPU dashboard 消费, 用于渲染
    每个模型的 ref / actual / status / duration 表格。所有写入失败都被静默吞掉,
    保证坏盘、权限错误或磁盘写满都不会让原本通过的测试变红。
    """
```

```
    path = envs.SGLANG_TEST_METRICS_FILE.get()
    if not path:
        # 环境变量未设置时直接返回, 这是本 PR “默认零影响” 的基线。
        return
```

```
    # sys.argv[0] 是测试脚本路径 (例如 `python3 test_foo.py` 直接运行时);
    # 渲染端按 test_file 分组聚合, file 级兜底记录不会与 model 级记录重复计数。
    test_file = os.path.basename(sys.argv[0]) if sys.argv and sys.argv[0] else ""
```

```
    try:
        # 以追加模式打开, 绝不截断或覆盖, 同一 runner 上并发进程不会互相踩踏。
        with open(path, "a") as f:
            for model, metrics in results.items():
                record = {
                    "kind": "model", # 与 ci_utils.py 里的 file 级记录区分用途
                    "test_file": test_file,
                    "model": model,
                    "accuracy": metrics.get("accuracy"),
                    "accuracy_threshold": metrics.get("accuracy_threshold"),
                    "output_throughput": metrics.get("output_throughput"),
                    "output_throughput_threshold": metrics.get(
                        "output_throughput_threshold"
                    ),
                    "latency": metrics.get("latency"),
                    "num_prompts": metrics.get("num_prompts"),
                    "num_threads": metrics.get("num_threads"),
                    "max_tokens": metrics.get("max_tokens"),
                    "error": metrics.get("error", ""),
                    "status": "pass" if not metrics.get("error") else "fail",
                }
                f.write(json.dumps(record) + "\n")
```

```
except OSError:
    # CI 安全底线：记录失败绝不能影响测试结果。
    pass
```

python/sglang/test/ci/ci_utils.py

为未走 model 级写入器的测试文件提供 file 级兜底记录（`kind=file`），任何加入 `run_suite.py` 的测试自动被 dashboard 覆盖；该文件影响所有套件的测试编排链路。

```
# 完全受保护的自动记录：`SGLANG_TEST_METRICS_FILE` 默认未设置，对所有非 XPU
# nightly 套件都是零差异；`OSError` 同样被吞掉，坏文件系统不能把通过的运行变红。
# 新增到 run_suite.py 的测试文件无需逐个接线，这里会自动拾取。
```

```
metrics_path = os.environ.get("SGLANG_TEST_METRICS_FILE")
```

```
if metrics_path:
```

```
    passed_set = set(passed_tests)
```

```
    failed_reasons = dict(failed_tests)
```

```
    try:
```

```
        with open(metrics_path, "a") as f:
```

```
            for fname, elapsed in file_elapsed.items():
```

```
                record = {
```

```
                    "kind": "file", # 文件级兜底，渲染端按 test_file 去重
```

```
                    "test_file": os.path.basename(fname),
```

```
                    "status": "pass" if fname in passed_set else "fail",
```

```
                    "duration": round(elapsed, 2),
```

```
                }
```

```
                if fname in failed_reasons:
```

```
                    record["error"] = failed_reasons[fname]
```

```
                f.write(json.dumps(record) + "\n")
```

```
    except OSError:
```

```
        pass
```

评论区精华

本 PR 没有公开 review 评论，只有一条 issue 评论：

"@MingxuZh could you please help review this one?" —— mingfeima

最终由 mingfeima 本人 APPROVED 并合并。真正的设计讨论藏在 PR body 与提交历史中：

- PR body 的 CI safety 三原则构成了整条管道的设计基线：① 未设置 env var 时无行为变化；② 所有 `OSError` 被吞掉，写入失败不能把通过的测试变红；③ 追加模式写入，绝不截断覆盖，并发 worker 互不踩踏。其中“无行为变化”的承诺只对 jsonl 写入严格成立——Markdown Step Summary 表格实际上新增了 Prompts 列，属于承诺之外的静态变化。
- commit 2a62b54 明确记录 schema 分歧是有意为之：num_prompts / num_threads / max_tokens 先只在 XPU 侧落地，test_ascend_utils.py 的对应改动“left for the Ascend maintainer”，避免一次性跨平台大改。
- commit 45c6c38 引入 file 级自动记录时为 model 级记录打 test_file 戳，代码注释说明渲染端按文件分组、避免 file 级 fallback 行与 model 级 rich 记录重复计数——这是双写路径的去重设计。

- PR body 声称“consumer 是 follow-up PR、本 PR 只是 plumbing”，但提交 77751a01 实际把 dashboard 也合入了（范围在演进中扩大），body 的描述已与合入内容不符。
- 暂无高价值评论线程

风险与影响

- 风险：
 1. “未设置时零变化”承诺不完整：test_xpu_utils.py 的 Markdown 表头与每行都新增了 Prompts 列，即使 SGLANG_TEST_METRICS_FILE 未设置，\$GITHUB_STEP_SUMMARY 的表格内容也始终变化；任何依赖旧列序解析 Step Summary 的脚本（包括 Ascend 侧镜像代码）可能受影响。
 2. env var 访问方式不一致：test_xpu_utils.py 走 envs.SGLANG_TEST_METRICS_FILE.get() descriptor，而 ci_utils.py 用 os.environ.get("SGLANG_TEST_METRICS_FILE")，违反 PR 自己宣称的 env-var conventions；未来若对变量做验证、别名或废弃处理，两条路径行为会分裂。
 3. 双写路径依赖渲染端去重：model 级记录与 file 级记录同时写入同一 jsonl，dashboard 若未严格按 test_file 分组会出现重复计数；test_file 取自 sys.argv[0]，在 pytest 或 runner import 场景下可能是空串或非预期值。
 4. 错误完全静默：except OSError: pass 意味着磁盘满、权限错误时 dashboard 数据静默缺失，故障不可见。
 5. 大段内嵌 Python 无测试守护：xpu-ci-job-monitor.yml 新增 363 行 heredoc 内嵌脚本（badge/health/sort_key 等），无单元测试、无 lint，shields.io badge 还依赖外网可达性；nightly-xpu-per-model-report 依赖 gh run list 解析与 artifact 下载，任一环节失败只靠 continue-on-error 兜底。
 6. 缺少自动化测试：PR 的验证全部为手动清单，jsonl schema、Step Summary 格式、双路径去重均无 CI 用例守护，后续改动容易静默破坏管道。
 - 影响：用户与产品运行时零影响：SGLANG_TEST_METRICS_FILE 默认 None，仓库内无既有调用方，environ.py 仅新增一个配置项注册。对系统的影响集中在 CI 侧：XPU nightly 三个作业（1/2/4-GPU）每次运行会额外写一个 jsonl 并上传 artifact（保留 30 天），xpu-ci-job-monitor.yml 新增两个 ubuntu-latest job 的渲染开销。对团队的价值是监控粒度从套件级降到模型级：能精确看到哪个模型、以多少吞吐 / 精度、对哪个门槛失败，并首次为 XPU nightly 提供历史可追溯的指标文件。该管道也为后续平台（Ascend、未来 8-GPU 套件）提供了可复制的模式；ci_utils.py 的 file 级记录对所有套件生效，其他 nightly 只要设置同一 env var 即可复用。
 - 风险标记：未设置 env var 时表格结构仍变化，缺少自动化测试覆盖，双写路径依赖渲染端去重，CI 脚本内嵌大段 Python 无测试守护，env var 访问方式不一致

关联脉络

- PR #35500 [CI/NPU] Isolate multi-node tests by run_id to prevent concurrent-run...：同为硬件（NPU/XPU）nightly CI 健壮性演进：按 run_id 隔离并发运行与本 PR 的 append-only 并发写入防护目标一致，都是让 nightly 结果可信的基础设施工作。

- PR #34074 [CI] Move tests onto the right CI stages: CI 测试分级与 workflow 矩阵化, 改动集中在同一测试编排链路 (run_suite.py / ci_utils.py 相关) ; 本 PR 在 ci_utils.py 的 run_unittest_files 中新增 file 级记录, 二者在共同演进测试执行框架。