

PR #29403 完整报告

sgl-project/sglang

feat: sync npu nightly test improvements from Ascend testcases

合并时间: 2026-07-06 22:41

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29403>

执行摘要

- 一句话: NPU 夜间测试增强: 重试、协调、参数调优
- 推荐动作: 值得关注的设计决策:
 - 数据集感知的阈值计算方法: 通过定义题目数量和波动容忍度, 为不同评估集设置差异化的准确率门槛, 减少误报。
 - 多次运行取平均的设计: 在测试基类中提供 `n_runs` 和 `run_accuracy_multiple`, 方便快速实现多次评估。
 - 环境变量注入和 CI 标志移除: 为性能基准测试提供更精确的环境控制。

建议阅读 `test_npu_accuracy_utils.py` 和 `test_npu_performance_utils.py` 中的工具函数设计。注意 review 中未解决的配置问题 (tp-size 不匹配、推理解析器缺少值等), 建议在后续 PR 中修复。

功能与动机

根据 PR body, 此 PR 的目的是从 Ascend 测试用例同步改进, 包括更新 `nightly-test-npu.yml` 的 `qwen3_6_27b` 配置 (2p→1p), 在准确性工具中添加多次运行和重试支持, 在多节点工具中添加 `ConfigMap` 操作函数, 以及在性能工具中添加环境变量参数等。最终目标是提升 NPU 夜间测试的覆盖率和可靠性。

实现拆解

1. CI 工作流调整(`nightly-test-npu.yml`): 将 `qwen3_6_27b_w8a8` 测试从双卡 (2p) 改为单卡 (1p), 同时保持 `a2 runner` 标签。
2. 准确性测试增强(`test_npu_accuracy_utils.py`):
 - 新增 `DATASET_QUESTION_COUNTS` 和 `DATASET_FLUCTUATION` 常量, 用于基于题目数量的绝对波动阈值计算。
 - 提供 `get_accuracy_threshold()` 和 `get_max_retries()` 函数, 使不同数据集使用不同的容忍度和重试次数。
 - 在 `TestNpuAccuracyTestCaseBase` 中添加 `n_runs` 类属性和 `run_accuracy_multiple()` 方法, 支持多次运行并报告平均准确率。
 - 删除废弃的 `MMMU_LOCAL_PATH` 和 `_get_dataset_args()` 方法。
3. 多节点测试工具新增(`test_npu_multi_node_utils.py`):

- 添加 `ACTIVE_TEST_CLASS` 和 `SERVICE_EXIT_WAIT_SECONDS` 常量。
 - 新增 `upsert_configmap_field_strict()`：使用 Kubernetes API 更新 ConfigMap 字段，若 ConfigMap 不存在则抛出 `RuntimeError`。
 - 新增 `wait_for_prefill_decode_exit()`：定期查询 ConfigMap，插入退出信号，并等待预填 / 解码节点退出（最多等待 `ROUTER_CONFIGMAP_TIMEOUT` 秒）。
4. 性能测试工具改进(`test_npu_performance_utils.py`):
- 为 `run_bench_serving()` 函数添加可选的 `env` 参数，允许调用方传入自定义环境变量字典（直接传递给 `subprocess.Popen`）。
 - 在三个测试基类中增加 `pop_sglang_is_in_ci_for_gsp` 标志，当为 `True` 且数据集为 `generated-shared-prefix` 时，在运行基准测试前移除 `SGLANG_IS_IN_CI` 环境变量。
 - 在 `TestNpuPerfMultiNodePdSepTestCaseBase.tearDownClass` 中增加轮询等待子进程退出的逻辑，并添加超时警告。
5. 测试用例同步调整：大量准确性 / 性能测试用例更新参数（如 `--max-mamba-cache-size`、`--mem-fraction-static`、`--cuda-graph-bs`、`--prefill-delayer-*` 等），添加 `--reasoning-parser` 和 `--tool-call-parser`，将类名从 `TestAscend` 改为 `TestNpu`，删除空置的 `setUpClass/tearDownClass` 等方法。新增 `test_npu_qwen3_6_27b_w8a8_1p_in64k_out1k_50ms.py` 单卡性能测试。

关键文件：

- `python/sglang/test/ascend/e2e/test_npu_accuracy_utils.py`（模块 准确率工具；类别 `test`；类型 `test-coverage`；符号 `get_accuracy_threshold`, `get_max_retries`, `_get_dataset_args`, `run_accuracy_multiple`）：准确性测试基础工具，新增数据集感知的阈值计算和重试逻辑，是本次变更的核心文件
- `test/registered/ascend/performance/qwen3_6_27b/test_npu_qwen3_6_27b_w8a8_1p_in64k_out1k_50ms.py`（模块 Qwen3.6 性能测试；类别 `test`；类型 `test-coverage`；符号 `TestNPUQwen3_6_27B_2P_In64k_Out1k_50ms`, `test_npu_qwen3_6_27b_2p_in64k_out1k_50ms`）：新增 Qwen3.6-27B-w8a8 单卡性能测试文件，配置了完整的启动参数和环境变量
- `python/sglang/test/ascend/e2e/test_npu_multi_node_utils.py`（模块 多节点工具；类别 `test`；类型 `test-coverage`；符号 `upsert_configmap_field_strict`, `wait_for_prefill_decode_exit`）：多节点测试工具，新增 `upsert_configmap_field_strict` 和 `wait_for_prefill_decode_exit`，用于 Kubernetes 环境下的测试协调
- `test/registered/ascend/performance/qwen3_6_27b/test_npu_qwen3_6_27b_2p_in64k_out1k_prefix90_50ms.py`（模块 前缀缓存测试；类别 `test`；类型 `test-coverage`；符号 `TestNPUQwen3_6_27B_2P_In64k_Out1k_Prefix90_50ms`, `TestNPUQwen3_6_27B_1P_In64k_Out1k_Prefix90_50ms`）：调整了前缀缓存性能测试类从 2p 改为 1p，同时更新了 `server args` 参数，并添加了推理工具调用解析器
- `python/sglang/test/ascend/e2e/test_npu_performance_utils.py`（模块 性能工具；类别 `test`；类型 `test-coverage`；符号 `run_bench_serving`, `pop_sglang_is_in_ci_for_gsp`）：性能测试工具，新增 `env` 参数、`pop_sglang_is_in_ci_for_gsp` 标志和进程退出等待逻辑

关键符号: get_accuracy_threshold, get_max_retries, run_accuracy_multiple, upsert_configmap_field_strict, wait_for_prefill_decode_exit, run_bench_serving, assert_metrics, TestNpuAccuracyTestCaseBase.run_accuracy, TestNpuPerformanceTestCaseBase.run_throughput, TestNpuPerfMultiNodePdMixTestCaseBase.run_throughput, TestNpuPerfMultiNodePdSepTestCaseBase.tearDownClass

关键源码片段

python/sglang/test/ascend/e2e/test_npu_accuracy_utils.py

准确性测试基础工具，新增数据集感知的阈值计算和重试逻辑，是本次变更的核心文件

```
# 数据集题目总数和允许的波动（绝对题数）
```

```
DATASET_QUESTION_COUNTS = {
```

```
    "aime25": 30,
```

```
    "aime26": 30,
```

```
    "gpqa_diamond": 198,
```

```
}
```

```
DATASET_FLUCTUATION = {
```

```
    "aime25": 2,
```

```
    "aime26": 2,
```

```
    "gpqa_diamond": 5,
```

```
}
```

```
MAX_RETRY_COUNT = 3 # 最大重试次数
```

```
def get_accuracy_threshold(datasets, baseline_accuracy):
```

```
    """根据数据集计算准确率阈值。
```

```
    对于有定义波动的数据集（如 aime, gpqa），使用绝对题数容忍度；
```

```
    其他数据集（如 mmmu）使用百分比容忍度。
```

```
    """
```

```
    dataset = datasets[0] if datasets else None
```

```
    if dataset in DATASET_FLUCTUATION and dataset in DATASET_QUESTION_COUNTS:
```

```
        # 波动比例 = 允许波动的题数 / 总题数
```

```
        fluctuation = DATASET_FLUCTUATION[dataset] / DATASET_QUESTION_COUNTS[dataset]
```

```
        return baseline_accuracy - fluctuation
```

```
    # 默认使用 99% 容忍度
```

```
    return baseline_accuracy * ACCURACY_TOLERANCE
```

```
def get_max_retries(datasets):
```

```
    """返回准确性测试的最大重试次数。
```

```
    gpqa 和 aime 数据集支持最多 MAX_RETRY_COUNT 次重试；
```

```
    mmmu 等其他数据集只执行 1 次（不重试）。
```

```
    """
```

```
    dataset = datasets[0] if datasets else None
```

```
    if dataset in DATASET_FLUCTUATION:
```

```
        return MAX_RETRY_COUNT
```

```
return 1
```

```
def assert_metrics(self, metrics):
    if not metrics:
        raise Exception("No metrics obtained from benchmark")
    if self.accuracy is not None:
        # 使用计算得到的阈值，而非固定的比例
        threshold = get_accuracy_threshold(self.datasets, self.accuracy)
        dump_metric("accuracy", float(metrics["accuracy"]),
                    labels={"test_case": self.__class__.__name__, "type": "accuracy"})
        dump_metric("accuracy_baseline", float(self.accuracy),
                    labels={"test_case": self.__class__.__name__, "type": "accuracy"})
        self.assertGreaterEqual(
            float(metrics["accuracy"]),
            threshold,
            f"Accuracy check failed. Expected >= {threshold}, Got: {metrics['accuracy']}",
        )
```

[test/registered/ascend/performance/qwen3_6_27b/test_npu_qwen3_6_27b_w8a8_1p_in64k_out1k_50ms.py](#)

新增 Qwen3.6-27B-w8a8 单卡性能测试文件，配置了完整的启动参数和环境变量

注意：此测试文件名及类名标记为 1p（单卡），但 --tp-size 设置为 2（双卡），
这是一个已知的配置冲突，可能在运行时导致错误或使用错误并行度。

```
QWEN3_6_27B_64K_1K_OTHER_ARGS = [
```

```
    "--tp-size",
    2, # 与单卡预期不符，应为 1
    "--nnodes",
    1,
    "--attention-backend",
    "ascend",
    "--device",
    "npu",
    "--chunked-prefill-size",
    -1,
    "--max-prefill-tokens",
    48000,
    "--disable-radix-cache",
    "--trust-remote-code",
    "--max-running-requests",
    6,
    "--max-mamba-cache-size",
    16,
    "--mem-fraction-static",
    0.6,
    "--cuda-graph-bs",
    1, 2, 4, 5, 6,
    "--quantization",
    "modelslim",
```

```

"--dtype",
"bfloat16",
"--mamba-ssm-dtype",
"bfloat16",
"--speculative-algorithm",
"NEXTN",
"--speculative-num-steps",
3,
"--speculative-eagle-topk",
1,
"--speculative-num-draft-tokens",
4,
"--reasoning-parser",
"qwen3",
"--tool-call-parser",
"qwen3_coder",
]

```

```

class TestNPUQwen3_6_27B_2P_In64k_Out1k_50ms(TestNpuPerformanceTestCaseBase):
    """Qwen3.6-27B-w8a8 单卡性能测试（但类名中的 2P 与意图 1P 矛盾）"""
    benchmark_tool = BENCHMARK_TOOL_DEFAULT
    dataset_type = AISBENCHMARK_DATASET_DEFAULT
    model = QWEN3_6_27B_W8A8_MODEL_PATH
    other_args = QWEN3_6_27B_64K_1K_OTHER_ARGS
    envs = QWEN3_6_27B_64K_1K_ENVS
    dataset_name = "random"
    max_concurrency = 6
    num_prompts = 12
    input_len = 64000
    output_len = 1000
    random_range_ratio = 1
    tpot = 50
    output_token_throughput = 57.85 # 期望的 output token throughput

    def test_npu_qwen3_6_27b_2p_in64k_out1k_50ms(self):
        self.run_throughput()

```

[python/sglang/test/ascend/e2e/test_npu_multi_node_utils.py](#)

多节点测试工具，新增 `upsert_configmap_field_strict` 和 `wait_for_prefill_decode_exit`，用于 Kubernetes 环境下的测试协调

```

# 以严格模式更新 ConfigMap 字段：若 ConfigMap 不存在则抛出异常
def upsert_configmap_field_strict(name: str, namespace: str, key: str, value: str):
    from kubernetes.client.rest import ApiException
    k8s_api = get_k8s_api()
    patch = {"data": {key: value}}
    try:
        k8s_api.patch_namespaced_config_map(name=name, namespace=namespace, body=patch)
        logger.info(f"Upserted ConfigMap {name}: {key}={value}")

```

```

except ApiException as e:
    if e.status == 404:
        raise RuntimeError(f"ConfigMap {name} does not exist in namespace {namespace}")
    logger.error(f"Failed to upsert ConfigMap {name}: {e}")
    raise

# 等待预填 / 解码节点退出: 通过 ConfigMap 发送信号并等待节点响应
def wait_for_prefill_decode_exit(
    key: str,
    value: str,
    timeout: int = ROUTER_CONFIGMAP_TIMEOUT,
    poll_interval: int = 15,
):
    start_time = time.time()
    while time.time() - start_time < timeout:
        configmap = query_configmap(CONFIGMAP_NAME, NAMESPACE)
        if not configmap or not configmap.data:
            logger.info(f"ConfigMap data is not available yet, waiting for {poll_interval}s...")
            time.sleep(poll_interval)
            continue
        existing_value = configmap.data.get(key)
        upsert_configmap_field_strict(CONFIGMAP_NAME, NAMESPACE, key, value)
        if existing_value is not None:
            logger.info("%s already set (%s), waiting %ds for prefill/decode to exit ...",
                        key, existing_value, SERVICE_EXIT_WAIT_SECONDS)
            time.sleep(SERVICE_EXIT_WAIT_SECONDS)
        else:
            logger.info("%s set for the first time (%s)", key, value)
    return

# 注意: 超时时函数静默返回 None, 未抛出错误

```

评论区精华

Review 中 [gemini-code-assist\[bot\]](#) 指出了四个关键问题:

- (critical) 推理解析器参数缺少值: 在 `test_npu_deepseek_v3_2_8p_aime25.py` 中 `--reasoning-parser` 后未提供值, 会导致服务器启动失败。
- (high) 单卡测试配置冲突: 新文件 `test_npu_qwen3_6_27b_w8a8_1p_in64k_out1k_50ms.py` 意图为单卡 (1p) 测试, 但 `--tp-size` 设置为 2。
- (high) 环境变量覆盖风险: `run_bench_serving` 的 `env` 参数直接传给 `subprocess.Popen`, 会完全替换子进程环境, 导致 `PATH` 等关键变量丢失。
- (medium) 等待函数超时处理缺失: `wait_for_prefill_decode_exit` 在超时时仅返回 `None`, 未抛出错误; 同时日志信息硬编码 15s 而非使用 `poll_interval`。

作者对 `tp-size` 评论回复 "a regular change", 但最终代码中该值仍为 2, 表明该问题未解决。其他评论未获得回复。PR 已合并, 这些 risk 仍存在。

- 推理解析器参数缺少值 (correctness): 未修复, PR 已合并, 问题仍存在。

- 单卡测试配置冲突 (`--tp-size`) (correctness): 已讨论但未修改, PR 合并时保留冲突。
- 环境变量覆盖风险 (performance): 未回应, PR 合并时保留风险。当前调用场景已复制 `os.environ` 再修改, 但函数接口设计仍有隐患。
- 等待函数超时处理缺失 (correctness): 未回应, PR 合并时保留问题。

风险与影响

- 风险:
 - 测试配置错误可能导致假失败 / 假通过: 部分测试用例的参数 (如 `--tp-size` 与单卡矛盾) 未修正, 可能在实际运行时报错或使用错误并行度, 导致性能数据失真或测试失败。
 - 环境变量覆盖风险: `run_bench_serving` 直接传递 `env` 会替换整个环境, 若调用方设置自定义环境但未包含系统关键变量 (如 `PATH`), 子进程可能无法运行。当前仅 `pop_sglang_is_in_ci_for_gsp` 场景使用 `env`, 该场景已复制 `os.environ` 并移除单个变量, 风险较低, 但函数接口设计仍存在安全隐患。
 - 超时沉默失败: `wait_for_prefill_decode_exit` 超时时静默返回, 可能导致多节点测试在等待阶段卡住或错误认为节点已退出, 增加调试难度。
 - 大范围测试重构可能引入回归: 涉及 37 个文件, 大量类名和方法签名调整, 缺少对应的回归测试覆盖。
- 影响:
 - 用户影响: 仅影响 NPU (Ascend) 平台的内部测试团队, 生产环境用户无直接感知。
 - 系统影响: NPU 夜间测试的准确性和性能测试流程将更稳定、灵活, 支持多次运行取平均和重试机制, 降低假阳性。
 - 团队影响: NPU 测试维护者获得更强大的工具函数, 减少了手动处理 `ConfigMap` 和轮询退出等操作, 提升测试编写效率。但存在上述风险点, 需要后续修复。
 - 风险标记: 测试配置不一致, 环境变量覆盖, 超时静默失败, 无回归测试

关联脉络

- PR #30047 Bugfix qwen prefix cache circumstances: 修复 NPU 前缀缓存相关 bug, 本 PR 调整了前缀缓存测试的参数 (如 `--max-mamba-cache-size`), 两者关联。
- PR #30048 [XPU] Unbreak stage-b: re-add `--disable-decode-cuda-graph`, quarantine EAGLE3 parity: 同属 CI 稳定性改进, 与本 PR 目标一致。
- PR #30186 Clean up ServerArgs post-init dispatch: 重构服务器参数调度, 本 PR 大量测试用例调整了 `server args` (如 `--reasoning-parser`、`--tool-call-parser`), 与参数清理相关。