

PR #23576 完整报告

sgl-project/sglang

[diffusion] CI: minor refactor CI

合并时间: 2026-04-24 08:48

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/23576>

执行摘要

- 一句话: 简化扩散测试用例组织结构, 合并列表并重命名文件
- 推荐动作: 该 PR 属于常规维护重构, 不涉及功能变更。建议阅读 `gpu_cases.py` 和 `diffusion_case_parser.py` 的变更, 了解测试组织方式的新约定。"1-gpu-b200" 测试套件的文件引用已更新, 注意保持同步。

功能与动机

简化扩散 CI 的测试用例组织方式, 减少碎片化列表, 使开发者更容易添加和查找测试用例。

实现拆解

1. 合并测试用例列表 (`python/sglang/multimodal_gen/test/server/gpu_cases.py`): 将 `ONE_GPU_CASES_A`、`ONE_GPU_CASES_B`、`ONE_GPU_CASES_C` 合并为 `ONE_GPU_CASES`, 并在文件末尾使用 `+=` 将 `ModelOpt` 用例追加到 `ONE_GPU_CASES` 中; 同理, 将 `TWO_GPU_CASES_A` 和 `TWO_GPU_CASES_B` 合并为 `TWO_GPU_CASES`, 并移除原有的拼接语句。
2. 重命名 `ModelOpt` 列表 (`gpu_cases.py`): 将 `ONE_GPU_CASES_C` 改为 `ONE_GPU_MODELOPT_CASES`, 更清晰地表明它包含 `ModelOpt` (量化) 测试用例。
3. 重命名测试文件 (`test_server_c.py` → `test_server_b200.py`): 将 B200 专用的测试文件更名, 并更新其导入语句使用新的列表名 `ONE_GPU_MODELOPT_CASES`。
4. 更新配套配置 (`testcase_configs.py`、`run_suite.py`): 修改文档注释中的列表引用, 以及 `run_suite.py` 中 `FILE_SUITES` 的条目, 将 `test_server_c.py` 替换为 `test_server_b200.py`。
5. 增强用例解析器 (`scripts/ci/utils/diffusion/diffusion_case_parser.py`): 新增 `visit_AugAssign` 方法以处理 `+=` 赋值, 新增 `_extract_case_ids` 方法支持变量引用和二进制加法操作, 并在 `_extract_case_ids_from_list` 中处理 `ast.Starred` 解包, 最后添加去重逻辑以保持列表顺序。

关键文件:

- `python/sglang/multimodal_gen/test/server/gpu_cases.py` (模块 测试用例; 类别 `test`; 类型 `test-coverage`): 核心变更文件, 合并了所有扩散测试用例列表并重命名了 `ModelOpt` 列表

- scripts/ci/utlils/diffusion/diffusion_case_parser.py (模块 CI 脚本; 类别 infra; 类型 infrastructure; 符号 visit_AugAssign, _extract_case_ids_from_list, _process_aug_assignment, _extract_case_ids) : 增强解析器以支持 += 赋值和变量引用, 确保新结构能被正确解析
- python/sglang/multimodal_gen/test/server/test_server_b200.py (模块 测试脚本; 类别 test; 类型 rename-or-move) : 文件重命名并更新导入, 与 gpu_cases.py 的新列表名对齐
- python/sglang/multimodal_gen/test/server/testcase_configs.py (模块 测试配置; 类别 test; 类型 test-coverage) : 更新文档注释中的列表名称引用
- python/sglang/multimodal_gen/test/run_suite.py (模块 运行脚本; 类别 test; 类型 test-coverage) : 更新文件引用以匹配重命名后的测试文件

关键符号: visit_AugAssign, _process_aug_assignment, _extract_case_ids, _extract_case_ids_from_list

关键源码片段

python/sglang/multimodal_gen/test/server/gpu_cases.py

核心变更文件, 合并了所有扩散测试用例列表并重命名了 ModelOpt 列表

```
# python/sglang/multimodal_gen/test/server/gpu_cases.py
# 合并前: ONE_GPU_CASES_A, ONE_GPU_CASES_B, ONE_GPU_CASES_C 三个独立列表
# 合并后: 统一为 ONE_GPU_CASES, 并在末尾追加 ModelOpt 用例
ONE_GPU_CASES: list[DiffusionTestCase] = [
    # === Text to Image (T2I) ===
    DiffusionTestCase("qwen_image_t2i", ...),
    DiffusionTestCase("qwen_image_t2i_cache_dit_enabled", ...),
    # ... 原有 A 和 B 的所有用例 ...
    DiffusionTestCase("flux_2_image_t2i_upscaling_4x", ...),
    # === Text to Video (T2V) === (原来在 B 中)
    DiffusionTestCase("wan2_1_t2v_1.3b", ...),
    # ...
]
# 平台条件追加 (原来分别追加到 A/B)
if not current_platform.is_hip():
    ONE_GPU_CASES.append(DiffusionTestCase("hunyuan3d_shape_gen", ...))
    ONE_GPU_CASES.append(DiffusionTestCase("turbo_wan2_1_t2v_1.3b", ...))
if current_platform.is_hip():
    ONE_GPU_MODELOPT_CASES = []
else:
    ONE_GPU_MODELOPT_CASES = [
        _make_modelopt_ci_case("flux1_modelopt_fp8_t2i", ...),
        # ...
    ]
# 使用 += 合并 (简化前是通过 [*A, *B, *C] 拼接)
ONE_GPU_CASES += ONE_GPU_MODELOPT_CASES

# 2-GPU 同理合并
```

```

TWO_GPU_CASES = [
    DiffusionTestCase("wan2_2_i2v_a14b_2gpu", ...),
    # ... 原来 A 和 B 的所有用例 ...
    DiffusionTestCase("flux_2_ti2i_multi_image_cache_dit", ...),
]
TWO_GPU_CASES = _with_default_num_gpus(TWO_GPU_CASES, 2)

```

scripts/ci/utils/diffusion/diffusion_case_parser.py

增强解析器以支持 += 赋值和变量引用，确保新结构能被正确解析

```

# scripts/ci/utils/diffusion/diffusion_case_parser.py
class CaseCollector(ast.NodeVisitor):
    # ...

    def visit_AugAssign(self, node: ast.AugAssign):
        """处理 += 这类赋值，用于合并列表"""
        self._process_aug_assignment(node.target, node.op, node.value)
        self.generic_visit(node)

    def _process_aug_assignment(self, target, op, value):
        """执行 += 的语义：将右侧case ID追加到左侧列表"""
        if not isinstance(target, ast.Name) or not isinstance(op, ast.Add):
            return
        rhs_case_ids = self._extract_case_ids(value)
        if rhs_case_ids is None:
            return
        lhs_case_ids = self.cases.get(target.id, [])
        # 合并并保留顺序
        self.cases[target.id] = [*lhs_case_ids, *rhs_case_ids]

    def _extract_case_ids(self, node):
        """通用提取：支持列表字面量、变量引用、列表加法"""
        if isinstance(node, ast.List):
            return self._extract_case_ids_from_list(node)
        if isinstance(node, ast.Name):
            return list(self.cases.get(node.id, [])) # 引用之前解析过的变量
        if isinstance(node, ast.BinOp) and isinstance(node.op, ast.Add):
            left_ids = self._extract_case_ids(node.left)
            right_ids = self._extract_case_ids(node.right)
            if left_ids is None or right_ids is None:
                return None
            return [*left_ids, *right_ids]
        return None

    def _extract_case_ids_from_list(self, node: ast.List):
        """从列表字面量中提取case ID"""
        case_ids = []
        for elt in node.elts:
            if isinstance(elt, ast.Starred):
                # 处理 *list 展开

```

```
starred = self._extract_case_ids(elt.value)
if starred:
    case_ids.extend(starred)
continue
case_id = self._extract_case_id_from_call(elt)
if case_id:
    case_ids.append(case_id)
return case_ids
# 后续还添加了去重逻辑：保留首次出现顺序
```

评论区精华

只收到一个来自 `gemini-code-assist[bot]` 的评论，建议将 `ONE_GPU_CASES += ONE_GPU_MODELOPT_CASES` 改为显式列表连接 `ONE_GPU_CASES = ONE_GPU_CASES + ONE_GPU_MODELOPT_CASES`，以避免就地修改可能带来的副作用。该建议未被采纳，PR 已合入当前实现。

- 使用 `+=` vs 显式列表连接 (design): PR 合入时未采纳建议，保留了 `+=` 写法。

风险与影响

- 风险：低风险。变更仅限于测试基础设施和配置，不涉及核心推理逻辑。主要风险在于：
 - 如果 `diffusion_case_parser.py` 的解析逻辑存在边界情况（如嵌套 `AugAssign`），可能导致 CI 解析失败。
 - 测试文件的移动和重命名可能影响历史 CI 配置或外部脚本引用。
 - 测试用例合并后，若某个用例被重复添加，去重逻辑可能隐藏问题。
 - 影响：影响范围：仅影响扩散（diffusion）测试套件的维护者和 CI 运行。影响程度：低。开发者添加新测试用例时只需操作 `ONE_GPU_CASES` 或 `TWO_GPU_CASES`，不再需要关心多个子列表。重命名和文件移动带来短暂的混乱，但整体简化了流程。
- 风险标记：测试配置变更，文件重命名

关联脉络

- 暂无明显关联 PR