

PR #49180 完整报告

vllm-project/vllm

[Bugfix][Benchmarks] Restore --skip-tokenizer-init with custom dataset

合并时间: 2026-07-24 19:30

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/49180>

执行摘要

- 一句话: 修复 custom dataset 与 --skip-tokenizer-init 的兼容性
- 推荐动作: 建议合入。修复明确, 测试充分。类型签名调整值得关注, 但已在合理范围内。

功能与动机

PR #39896 在 serve.py 的 main_async 中添加了全局 assert tokenizer is not None, 导致使用 --skip-tokenizer-init 配合 --dataset-name custom 的基准测试 (如 Prithvi-EO 地理空间模型) 直接抛出 AssertionError。

实现拆解

1. 移除全局断言 (vllm/benchmarks/serve.py): 删除 main_async 中的 assert tokenizer is not None, 并将 calculate_metrics 和 benchmark 的 tokenizer 类型改为 TokenizerLike | None。
2. 按需断言 (vllm/benchmarks/datasets/datasets.py): 将 get_samples 的 tokenizer 参数类型放宽为 TokenizerLike | None。在依赖 tokenizer 的数据集分支 (sonnet、hf、timed_trace 及通用 else) 中添加针对性 assert tokenizer is not None; 对 custom、custom_image、custom_audio 分支不做要求。
3. 测试覆盖 (tests/benchmarks/test_skip_tokenizer_init.py): 新增回归测试, 直接调用 main_async() 并 mock 网络请求, 验证 --skip-tokenizer-init + --dataset-name custom 不再抛出 AssertionError。

关键文件:

- vllm/benchmarks/datasets/datasets.py (模块 数据集加载; 类别 source; 类型 core-logic; 符号 get_samples): 核心修改: 将 get_samples 的 tokenizer 参数改为可空, 并在需要 tokenizer 的分支添加针对性断言。
- vllm/benchmarks/serve.py (模块 主流程; 类别 source; 类型 core-logic): 移除全局断言, 修改 calculate_metrics 和 benchmark 的类型签名以允许 tokenizer 为 None。
- tests/benchmarks/test_skip_tokenizer_init.py (模块 测试覆盖; 类别 test; 类型 test-coverage; 符号 _write_dataset, _args, test_main_async_skip_tokenizer_init_does_not_raise): 新测试文件, 提供回归验证, 确保修复后可正常工作。

关键符号: get_samples, main_async, calculate_metrics, benchmark

关键源码片段

vllm/benchmarks/datasets/datasets.py

核心修改：将 `get_samples` 的 `tokenizer` 参数改为可空，并在需要 `tokenizer` 的分支添加针对性断言。

```
def get_samples(args, tokenizer: TokenizerLike | None) -> list[SampleRequest]:
    # 初始化一些默认值
    if not hasattr(args, "request_id_prefix"):
        args.request_id_prefix = ""
    if hasattr(args, "random_range_ratio") and isinstance(args.random_range_ratio, str):
        args.random_range_ratio = _parse_range_ratio(args.random_range_ratio)

    # Custom 数据集: sample() 内部处理了 tokenizer=None 情形
    if args.dataset_name == "custom":
        dataset = CustomDataset(dataset_path=args.dataset_path, ...)
        input_requests = dataset.sample(tokenizer=tokenizer, ...)
    elif args.dataset_name == "custom_image":
        ... # 类似, 不强制 tokenizer
    elif args.dataset_name == "custom_audio":
        ... # 类似, 不强制 tokenizer
    elif args.dataset_name == "sonnet":
        # Sonnet 数据集需要 tokenizer 进行 chat template 格式化
        assert tokenizer is not None, "Tokenizer must be initialized for the 'sonnet' dataset."
        sonnet_dataset = SonnetDataset(...)
        input_requests = sonnet_dataset.sample(tokenizer=tokenizer, ...)
    elif args.dataset_name == "hf":
        assert tokenizer is not None, "Tokenizer must be initialized for the 'hf' dataset."
        ...
    elif args.dataset_name == "timed_trace":
        assert tokenizer is not None, "Tokenizer must be initialized for the 'timed_trace' dataset."
        ...
    else:
        # 其他数据集也要求 tokenizer
        assert tokenizer is not None, f"Tokenizer must be initialized for the '{args.dataset_name}' dataset."
        dataset_mapping = {...}
        ...
    return input_requests
```

tests/benchmarks/test_skip_tokenizer_init.py

新测试文件，提供回归验证，确保修复后可正常工作。

```
import argparse, asyncio, json
from pathlib import Path
from unittest.mock import AsyncMock, patch
import pytest
import vllm.benchmarks.serve as serve_module
```

```

# 模拟 Prithvi-EO 数据集的 prompt
_PRITHVI_PROMPT = {
    "data": {
        "data": "https://.../India_900498_S2Hand.tif",
        "data_format": "url",
        "out_data_format": "b64_json",
        "indices": [1, 2, 3, 8, 11, 12],
    },
    "priority": 0,
    "softmax": False,
}

def _write_dataset(path: Path) -> None:
    # 写入一行 JSON 作为数据集
    path.write_text(json.dumps({"prompt": _PRITHVI_PROMPT}) + "\n")

def _args(dataset_path: str) -> argparse.Namespace:
    # 构造与 --skip-tokenizer-init 真实调用等价的 Namespace
    return argparse.Namespace(
        dataset_name="custom",
        dataset_path=dataset_path,
        tokenizer=None,
        skip_tokenizer_init=True,
        backend="vllm-pooling",
        # ... 其他参数省略, 但保持与生产代码一致 ...
    )

@pytest.mark.benchmark
def test_main_async_skip_tokenizer_init_does_not_raise(tmp_path: Path) -> None:
    # 回归测试: 确保不会抛出 AssertionError
    dataset_path = tmp_path / "dataset.jsonl"
    _write_dataset(dataset_path)
    args = _args(str(dataset_path))
    # Mock benchmark 避免真实网络请求
    with patch.object(serve_module, "benchmark", AsyncMock(return_value={})):
        asyncio.run(serve_module.main_async(args))

```

评论区精华

无实质 review 讨论。作者在 Issue 评论中说明 CI 失败的 4 个测试与本 PR 无关，属于环境问题（No module named 'vllm._C'）。审核者 DarkLight1337 直接批准。

- CI 测试失败原因 (testing): 确认 CI 失败由环境问题引起，非本 PR 引入。

风险与影响

- 风险：风险低：修改仅限于 benchmark 命令行工具，不影响核心推理。需注意 tokenizer: TokenizerLike | None 类型变更可能影响外部直接调用者，但 benchmark 模块通常不对外暴露。测试覆盖了关键回归路径，各依赖 tokenizer 的分支仍保持原有断言，行为不变。
- 影响：修复了回归，恢复无 tokenizer 模型（如 Prithvi-EO）的基准测试能力。对已有使用 sonnet/hf 等数据集的行为无影响。影响范围限于使用 --skip-tokenizer-init 的 benchmark 用户。
- 风险标记：回归修复，类型签名变更

关联脉络

- PR #39896 [MyPy] Fix mypy for vllm/benchmarks: 该 PR 引入的全局断言导致本 PR 修复的回归问题。