

PR #36638 完整报告

sgl-project/sglang

Fix KeyError on batch requests whose state is freed before it is read

合并时间: 2026-08-29 03:57

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36638>

执行摘要

- 一句话: 修复批处理请求状态提前释放导致的 `KeyError`, 改为预解析状态
- 推荐动作: 建议精读, 该 PR 展示了异步生成器生命周期与状态管理的经典陷阱, 值得学习。
设计决策: 将状态解析提前到生成器构建时, 避免状态失效。

功能与动机

批处理请求中, 若某个请求在迭代前完成, 其状态会被 `_handle_batch_output` 删除, 导致生成器推进时 `KeyError`, 进而整个批次失败。多模态批次每次都会触发, 导致夜间 `test_vlms_perf.py` 失败。

实现拆解

1. 将 `_wait_one_response` 改为普通函数: 从 `async def` 改为 `def`, 在函数体内立即执行 `state = self.rid_to_state[obj.rid]`, 然后返回 `self._stream_one_response(obj=obj, state=state, request=request)`。这样状态查找在生成器创建时完成, 而非推进时, 避免状态删除后 `KeyError`。
2. 新增 `_stream_one_response` 异步生成器: 将原 `_wait_one_response` 中的循环逻辑移到新函数, 接受已解析的 `state` 参数, 不再依赖 `rid_to_state`。
3. 保持调用点不变: 所有五处调用 `_wait_one_response` 的地方无需修改, 兼容性良好。
4. 添加回归测试: 新增 `TestWaitOneResponseAfterStateFreed`, 模拟先构建 waiter 再释放状态的场景, 验证输出仍能传递。测试使用 `_handle_batch_output` 触发状态删除, 并断言输出内容正确。

关键文件:

- `python/sglang/srt/managers/tokenizer_manager.py` (模块 调度器; 类别 `source`; 类型 `core-logic`; 符号 `_wait_one_response`, `_stream_one_response`): 核心修复文件, 修改 `_wait_one_response` 和新增 `_stream_one_response`, 解决状态提前释放导致的 `KeyError`。
- `test/registered/unit/managers/test_tokenizer_manager_rid_cleanup.py` (模块 测试; 类别 `test`; 类型 `test-coverage`; 符号 `TestWaitOneResponseAfterStateFreed`, `test_generator_built_before_finish_still_delivers_output`, `drive`): 新增回归测试, 验证状态提前释放后生成器仍能传递输出, 防止回归。

关键符号: `_wait_one_response`, `_stream_one_response`,
`test_generator_built_before_finish_still_delivers_output`

关键源码片段

`python/sglang/srt/managers/tokenizer_manager.py`

核心修复文件, 修改 `_wait_one_response` 和新增 `_stream_one_response`, 解决状态提前释放导致的 `KeyError`。

```
# python/sglang/srt/managers/tokenizer_manager.py

def _wait_one_response(
    self,
    obj: Union[GenerateReqInput, EmbeddingReqInput],
    request: Optional[fastapi.Request] = None,
):
    # Batch dispatch builds every waiter before advancing any.
    # Both removers append the output after the del, so the ReqState stays valid.
    # 关键: 状态查找在生成器创建时完成, 避免生成器推进时状态已删除导致 KeyError。
    state = self.rid_to_state[obj.rid]
    return self._stream_one_response(obj=obj, state=state, request=request)

async def _stream_one_response(
    self,
    obj: Union[GenerateReqInput, EmbeddingReqInput],
    state: ReqState,
    request: Optional[fastapi.Request] = None,
):
    # 原 _wait_one_response 的异步逻辑移到这里, 使用已解析的 state。
    is_stream = getattr(obj, "stream", False)
    while True:
        try:
            await asyncio.wait_for(
                state.event.wait(), timeout=_REQUEST_STATE_WAIT_TIMEOUT
            )
        except asyncio.TimeoutError:
            if (
                request is not None
                and not obj.background
                and await request.is_disconnected()
            ):
                # 处理客户端断连, 中止请求。
                self.abort_request(obj.rid)
                raise ValueError(
                    f"Request is disconnected from the client side (type 1). Abort request {obj.rid=}"
                )
            continue

    # 原子地清空待处理输出。
```

```

out_list = state.out_list
state.out_list = []
finished = state.finished
state.event.clear()

# 增量流式时合并多个分块，避免丢失 token 编号。
incremental_stream = is_stream and self.incremental_streaming_output
if incremental_stream and len(out_list) > 1:
    # ... 合并逻辑 ...
    pass
# ... 其余处理 ...

```

test/registered/unit/managers/test_tokenizer_manager_rid_cleanup.py

新增回归测试，验证状态提前释放后生成器仍能传递输出，防止回归。

test/registered/unit/managers/test_tokenizer_manager_rid_cleanup.py

```
class TestWaitOneResponseAfterStateFreed(CustomTestCase):
```

```
    """状态在读取前释放时，waiter 仍须传递输出。
```

```

    批处理派发会先构建所有 waiter，再统一推进；
    调度器响应路径在请求完成时立即移除 rid_to_state。
    """

```

```
def test_generator_built_before_finish_still_delivers_output(self):
```

```

    tm = _make_tokenizer_manager(self)
    tm.request_logger = Mock()
    tm.request_metrics_exporter_manager = MagicMock()
    tm.request_metrics_exporter_manager.exporter_enabled.return_value = False
    rid = "freed_state_rid"
    state = _make_req_state(rid)
    state.obj.background = True # 跳过 fastapi 断连探测
    tm.rid_to_state[rid] = state

```

```
    async def drive():
```

```

        # 关键：先构建生成器，再触发状态删除。
        waiter = tm._wait_one_response(state.obj, None)
        await tm._handle_batch_output(_make_batch_str_output(rid))
        self.assertNotIn(rid, tm.rid_to_state)
        return await waiter.__anext__()

```

```
    out = asyncio.run(drive())
```

```

    # 断言输出仍能正确传递。
    self.assertEqual(out["meta_info"]["id"], rid)
    self.assertEqual(out["text"], "hello")

```

评论区精华

无

- 暂无高价值评论线程

风险与影响

- 风险：风险较低。`_wait_one_response` 签名未变，调用点不变，行为差异仅在状态查找时机。
可能的风险：如果其他代码依赖生成器创建时不执行状态查找（例如延迟错误抛出），则可能改变行为，但当前代码库中无此类依赖。测试新增覆盖了状态释放场景，但未涉及并发或多请求并发场景，建议后续补充。
- 影响：对用户而言，修复了多模态批处理请求的偶发 `KeyError`，提高了稳定性。对系统而言，改动核心路径但影响面小，所有调用点兼容。对团队而言，增强了测试覆盖，有助于防止回归。
- 风险标记：核心路径变更，测试覆盖薄弱（仅单测，缺并发场景）

关联脉络

- PR #36738 [HiCache] Fence load-back behind the forward stream: 两者都涉及调度器状态管理，但关联较弱。