

PR #28408 完整报告

sgl-project/sglang

Remove stale load collection from output streaming hot path

合并时间: 2026-06-18 06:02

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28408>

执行摘要

- 一句话: 移除输出热路径中过时的负载收集
- 推荐动作: 建议在合并前优先解决 WatchLoadUpdateReq 被外部包导入的兼容性问题, 可以为 smg-grpc-servicer 提供兼容性 shim 或标记为弃用。PR 本身逻辑正确, 但缺少测试覆盖, 建议补充单元测试验证移除后不影响核心路径。值得关注的设计决策是清理旧 API 时需充分评估外部依赖。

功能与动机

PR #26348 已将 DP 负载更新和 `/v1/loads` 端点迁移到共享内存负载快照, 但输出流热路径仍调用 `get_loads(include=["core"])` 并将结果附加到 `BatchTokenIDOutput.load` 中。此 piggybacked load 已不再被主负载路径使用, 因此可以安全移除, 以简化热路径并减少不必要的开销。

实现拆解

1. 删除 `BatchTokenIDOutput.load` 和 `BatchStrOutput.load` 字段: 在 `io_struct.py` 中移除这两个数据类的 `load: GetLoadsReqOutput = None` 字段定义, 消除响应结构中的负载携带。
2. 移除 `_stream_output_generation` 中的负载查询: 在 `output_streamer.py` 中删除对 `self.load_inquirer_get_loads(GetLoadsReqInput(include=["core"]))` 的调用, 以及将结果传递给 `acc.to_payload(load=load)` 的逻辑。方法签名也从 `to_payload` 中移除 `load` 参数。
3. 移除 `TokenizerManager._handle_batch_output` 中的负载附加逻辑: 在 `tokenizer_manager.py` 中删除从 `recv_obj.load` 提取 `num_running_reqs` 和 `num_waiting_reqs` 并注入到响应 `meta_info` 的代码块。
4. 删除 `WatchLoadUpdateReq` 数据类: 在 `io_struct.py` 中移除整个 `WatchLoadUpdateReq` 定义, 因为其不再被使用。
5. 清理 `SchedulerOutputStreamer` 和 `Scheduler` 中的负载相关注入: 从 `output_streamer.py` 的类定义中移除 `load_inquirer_get_loads` 字段, 并从 `scheduler.py` 的 `init_output_streamer` 中移除对应的 `lambda` 传参。

关键文件:

- `python/sglang/srt/managers/io_struct.py` (模块 数据结构; 类别 source; 类型 core-logic; 符号 WatchLoadUpdateReq): 移除了 `BatchTokenIDOutput.load`、

BatchStrOutput.load 字段和整个 WatchLoadUpdateReq 数据类，是清理的核心所在。

- python/sglang/srt/managers/tokenizer_manager.py (模块 Token 管理器；类别 source；类型 core-logic)：移除了从响应 meta_info 中提取负载信息的逻辑块，减少每个请求处理路径上的开销。
- python/sglang/srt/managers/scheduler_components/output_streamer.py (模块 输出流；类别 source；类型 core-logic)：删除了从 output_streamer 类中调用 load_inquirer_get_loads 的代码，并移除了 to_payload 方法的 load 参数，这是清理热路径负载收集的关键。
- python/sglang/srt/managers/scheduler.py (模块 调度器；类别 source；类型 core-logic)：移除 init_output_streamer 中 load_inquirer_get_loads 的 lambda 传参，是与 output_streamer 配套的清理。

关键符号：_stream_output_generation, _handle_batch_output, to_payload

关键源码片段

python/sglang/srt/managers/io_struct.py

移除了 BatchTokenIDOutput.load、BatchStrOutput.load 字段和整个 WatchLoadUpdateReq 数据类，是清理的核心所在。

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

# 之前：
# @dataclass
# class BatchTokenIDOutput:
# ...
# load: GetLoadsReqOutput = None # 已移除

# 之前：
# @dataclass
# class BatchStrOutput:
# ...
# load: GetLoadsReqOutput = None # 已移除

# 之前：
# @dataclass
# class WatchLoadUpdateReq(BaseReq):
# loads: List[GetLoadsReqOutput]
# 已完全移除，但被 smg-grpc-servicer 外部包依赖
```

python/sglang/srt/managers/tokenizer_manager.py

移除了从响应 meta_info 中提取负载信息的逻辑块，减少每个请求处理路径上的开销。

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

async def _handle_batch_output(self, recv_obj):
    for i, rid in enumerate(recv_obj.rids):
        state = self.rid_to_state.get(rid, None)
```

```

# ...
meta_info = {
    "id": rid,
    "finish_reason": recv_obj.finished_reasons[i],
    "prompt_tokens": recv_obj.prompt_tokens[i],
    "weight_version": self.server_args.weight_version,
    "num_retractions": recv_obj.retraction_counts[i],
}

# 以下代码块已被移除：
# load = getattr(recv_obj, "load", None)
# if load is not None:
#     num_running_reqs = getattr(load, "num_running_reqs", None)
#     num_waiting_reqs = getattr(load, "num_waiting_reqs", None)
#     if num_running_reqs is not None:
#         meta_info["num_running_reqs"] = num_running_reqs
#     if num_waiting_reqs is not None:
#         meta_info["num_waiting_reqs"] = num_waiting_reqs

if self.enable_metrics:
    if recv_obj.time_stats is not None:
        scheduler_time_stats = recv_obj.time_stats[i]
        meta_info.update(scheduler_time_stats.convert_to_output_meta_info())
# ... 继续处理

```

python/sglang/srt/managers/scheduler_components/output_streamer.py

删除了从 `output_streamer` 类中调用 `load_inquirer_get_loads` 的代码，并移除了 `to_payload` 方法的 `load` 参数，这是清理热路径负载收集的关键。

```
# python/sglang/srt/managers/scheduler_components/output_streamer.py
```

```

@dataclass(kw_only=True, slots=True)
class SchedulerOutputStreamer:
    send_to_detokenizer: zmq.Socket
    tree_cache: BasePrefixCache
    ps: ParallelState
    server_args: ServerArgs
    is_generation: bool
    spec_algorithm: SpeculativeAlgorithm
    disaggregation_mode: DisaggregationMode
    enable_hicache_storage: Callable[[], bool]
    # load_inquirer_get_loads: Callable[..., Any] # 已移除
    _test_stream_output_count: int = 0

    def _stream_output_generation(self, reqs, ...):
        # ... 构造 acc ...
        # load = self.load_inquirer_get_loads(GetLoadsReqInput(include=["core"])) # 已移除
        for req in reqs:
            # ...

```

```
payload = acc.to_payload(  
    # load=load, # 已移除  
    dp_rank=self.ps.dp_rank,  
    is_idle_batch=is_idle_batch,  
    has_reqs=bool(reqs),  
)
```

评论区精华

评审中，[gemini-code-assist\[bot\]](#) 自动评论确认无额外反馈。[ShangmingCai](#) 批准了变更，并邀请作者协助审查 PR #26561，在 PD 分解设置下联合推进解码端负载均衡。[@junliu-mde](#) 在 Issue 评论中指出，移除 `WatchLoadUpdateReq` 会导致 gRPC 模式下 `smg-grpc-servicer` 依赖该符号的导入失败 (`ImportError: cannot import name 'WatchLoadUpdateReq' from 'sglang.srt.managers.io_struct'`)。这一兼容性问题在 PR 合并前未被解决。

- `WatchLoadUpdateReq` 被外部包依赖导致 gRPC 模式不可用 (correctness): 未在 PR 合并前解决，这是一个已识别的回归 bug。

风险与影响

- 风险:
 1. gRPC 模式兼容性风险: `WatchLoadUpdateReq` 被 `smg-grpc-servicer` 包导入，PR 直接删除该符号会导致 gRPC 模式无法使用（已由 [@junliu-mde](#) 在 Issue 中确认）。这是一个回归性 bug，影响在生产环境中使用 gRPC 接口的用户。
 2. 缺少测试覆盖: PR 未对移除的负载携带逻辑添加任何适配性测试，移除后原有依赖该负载信息的客户端可能遇到 `meta_info` 中缺少 `num_running_reqs` / `num_waiting_reqs` 字段的问题，但 PR 未提供迁移路径。
 - 影响: 影响范围: 中等。移除的代码位于输出流热路径和 `TokenizerManager` 中，涉及请求响应的构建流程。影响程度: 高。对于使用 gRPC 模式的用户，该 PR 直接导致 `smg-grpc-servicer` 导入失败，功能不可用；对于 HTTP 接口，`num_running_reqs` / `num_waiting_reqs` 字段将从响应中消失，依赖这些字段进行客户端流量控制的客户端需迁移到 `/v1/loads` 端点。影响团队: 维护 `smg-grpc-servicer` 的团队需要更新依赖适配移除的符号；所有依赖响应负载字段的客户端团队需要调整。
- 风险标记: 缺少测试覆盖，外部依赖破坏，核心路径变更

关联脉络

- PR #26348 Move DP load updates and `/v1/loads` to shared-memory load snapshots: 本 PR 是 #26348 的后续清理，移除其迁移后过时的 load 携带代码。
- PR #24000 DP balancing and `/v1/loads` continue to read from load snapshots: 引入了早期的负载 piggyback 机制，本 PR 移除了该机制过时的部分。