

PR #34608 完整报告

sgl-project/sglang

Publish per-scheduler load on a dedicated socket for load-aware routers

合并时间: 2026-08-27 19:33

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34608>

执行摘要

- 一句话: 为负载感知路由器新增 per-scheduler 负载发布 socket
- 推荐动作: 值得精读。这是为外部路由器提供真实负载数据的基础设施 PR, 设计质量高: 端口推导与广播单一来源、opt-in 保护升级兼容、去心跳保证迁移及时性、golden bytes 钉跨语言契约。对计划接入 sgl-router cache_aware_zmq 或自研负载感知路由的团队, 这是必读的引擎侧对接规范; 对一般模型服务团队, 只需确认 `--load-publish-endpoint` 默认关闭、升级无影响即可。

功能与动机

PR body 明确指出: `cache-aware-zmq` 路由器用路由器侧的 in-flight 计数器推断 worker 负载, 该计数器只统计「当前这个路由器」派发的请求, 漏掉其他路由器与直连客户端流量; 且流式响应期间计数会一直保持到响应结束, 而不是请求真正占据 scheduler 的时间。引擎内部其实已算出正确数字——`SchedulerLoadInquirer.get_loads()` 每个发布周期产出 `LoadSnapshot` (喂给 `/v1/loads` 与 DP-attention 调度), 本 PR 就是把这快照暴露给进程外消费者, 让路由器按真实队列深度 / KV 占用为 worker 定价。该能力从生产分支移植到 main, 路由器侧消费者另行落地。

实现拆解

1. 参数入口与启动校验 (`server_args.py`): `observability` 命名空间新增 `--load-publish-endpoint` (off / auto / 显式 tcp:// 地址), 默认关闭; 新增 `check_load_publish_args` 在入口校验——未配 `--kv-events-config`、不可绑定或与 KV 范围重叠时直接拒绝启动, 而不是在 scheduler 子进程里只告警。显式地址仅接受通配主机 (`* / 0.0.0.0 / [::]`), 具体主机地址会被判为 connect 风格而拒绝广播。
2. 端口解析收敛到单一 resolver (`disaggregation/kv_events.py`): 新增 `is_kv_publisher_rank` (pp / attn-TP / attn-CP rank 0 的统一 gating, KV 发布者与负载发布者共用, 否则二者基于 `/server_info` 推导的端口会不一致)、`parse_tcp_port`、`parse_advertisable_tcp`、`parse_bindable_tcp` 与 `resolve_load_pub_range`。绑定方 `SchedulerLoadPublisher` 与广播方 `describe_kv_events_publisher` 都走同一 resolver, 引擎不可能广播一个自己不会绑定的范围; `auto` 模式紧贴 KV 事件范围之后打包 (base + dp_size 起), 与相邻 replay ROUTER 范围重叠时自动跳过。
3. 核心发布者 (新增 `load_publisher.py`, 267 行): `LoadStat` 是 msgspec struct (`array_like=True + tag=True`, Wire 形状 `["LoadStat", num_running_reqs,`

num_waiting_reqs, num_tokens, max_total_num_tokens, attn_dp_rank])，帧格式复用 KV 事件 socket ([b"load", 大端 i64 seq, msgpack LoadStat])；_open_pub_socket 绑定 PUB socket (HWM=8、LINGER=0、IPv6 开关)，刻意不用 get_zmq_socket 因为它设置的 SNDHWM=0 会破坏 HWM 语义；SchedulerLoadPublisher 负责调用节流 (LOAD_PUBLISH_INTERVAL=5)、去重心跳 (未变化 1 秒重发、变化立即发，迁移永不延迟) 与 best-effort 失败处理 (每个失败 episode 只记一次日志、不崩溃调度循环，路由器可回退到自己的计数器)。传输是同步 PUB socket (send 只是入队到 ZMQ IO 线程)，无后台线程与回放缓冲。

4. 调度器接线与快照复用 (scheduler.py)：init_load_publisher 创建发布者并使用与 DP 均衡 writer 相同的发布间隔；publish_load_snapshot 改为返回实际发布的 LoadSnapshot (对下游 override 是破坏性变更)，使 load socket 直接复用 DP 均衡 sink 已算好的快照，避免二次 O(queue) 遍历；on_idle 在 stalled (无 batch 但未 fully idle，如 KV 压力下队列停摆、disagg 转移) 路径也发布负载，并用 LOAD_STALL_REFRESH_S = 0.05 墙钟下限约束该自旋路径上两个 sink 的 get_loads 频率。
5. 测试与文档配套：test_loadstat_wire.py 用 golden hex 钉死 Wire 编码并覆盖 port/rank gating (CPU-only, socket bind 在 _open_pub_socket 处 stub)；test_server_info.py 覆盖 auto 跳过 replay 范围、显式地址迁移广播 base、connect 风格 KV 端点省略 load 键、IPv6 括号保留与裸 IPv6 拒绝等；test_kv_events.py 覆盖 resolve_load_pub_range 的 off / auto / 冲突 / u16 溢出分支；test_scheduler_on_idle_load.py 验证 stalled 自旋路径 50ms 节流；docs 的 server arguments 表格补充端口占用与放置说明。

关键文件：

- python/sglang/srt/managers/scheduler_components/load_publisher.py (模块 负载发布；类别 source；类型 core-logic；符号 LoadStat, _open_pub_socket, SchedulerLoadPublisher, init)：核心新组件：定义 Wire 契约 LoadStat 与 SchedulerLoadPublisher 发布者，含调用节流、去重心跳、HWM 语义与 best-effort 失败处理。
- python/sglang/srt/disaggregation/kv_events.py (模块 端口解析；类别 source；类型 dependency-wiring；符号 is_kv_publisher_rank, LOAD_TOPIC, parse_tcp_port, parse_advertisable_tcp)：端口推导中枢：新增 is_kv_publisher_rank、parse_* 与 resolve_load_pub_range，绑定与广播共用同一 resolver，防止引擎广播自己不会绑定的范围。
- python/sglang/srt/managers/scheduler.py (模块 调度器；类别 source；类型 core-logic；符号 init_load_publisher, publish_load_snapshot)：接线与快照复用：init_load_publisher 接线新组件，publish_load_snapshot 改为返回快照供发布者复用，stalled no-batch 路径发布负载并限流。
- python/sglang/srt/server_args.py (模块 启动参数；类别 source；类型 configuration；符号 check_load_publish_args, load_publish_endpoint)：新增 --load-publish-endpoint 参数 (默认 off) 与 check_load_publish_args 启动校验，防止未绑定或重叠范围。
- python/sglang/srt/managers/scheduler_components/kv_events_publisher.py (模块 KV 发布者；类别 source；类型 core-logic)：移除重复的 rank gating 内联判断，复用新抽出的 is_kv_publisher_rank，保持两个发布者门控一致。

- test/registered/unit/managers/test_loadstat_wire.py (模块 负载协议; 类别 test; 类型 test-coverage; 符号 TestLoadStatWire, test_loadstat_golden_bytes, test_loadstat_msgpack_array_shape, test_loadstat_tag_is_class_name) : golden bytes 钉死跨语言 Wire 编码, 覆盖 port/rank gating 与默认关闭语义, 是 Wire 契约的权威测试。
- test/registered/unit/entrypoints/test_server_info.py (模块 服务信息; 类别 test; 类型 test-coverage; 符号 test_load_port_skips_an_overlapping_replay_range, test_explicit_load_publish_endpoint_moves_the_advertised_base, test_load_keys_omitted_for_connect_style_kv_endpoint, test_load_keys_omitted_when_explicitly_off) : 覆盖 /server_info load 端口广播的各类边界: replay 冲突、显式地址迁移、IPv6 括号、connect 风格省略与 off 显式关闭。
- test/registered/unit/disaggregation/test_kv_events.py (模块 KV 事件; 类别 test; 类型 test-coverage; 符号 TestResolveLoadPubRange, test_off_by_default, test_auto_packs_after_kv_range, test_auto_skips_an_overlapping_replay_range) : 覆盖 resolve_load_pub_range 各分支: off 默认、auto 打包、replay 冲突跳过、connect 风格拒绝与 u16 溢出拒绝。
- test/registered/unit/managers/test_scheduler_on_idle_load.py (模块 空闲发布; 类别 test; 类型 test-coverage; 符号 TestOnIdleStallPublish, test_spinning_stall_publishes_once_within_the_floor, test_publishes_again_after_the_floor_elapses) : 验证 stalled 自旋路径的 50ms 墙钟节流, 确保 on_idle 高频调用不会放大 get_loads 开销。
- docs/docs/advanced_features/server_arguments.mdx (模块 文档; 类别 docs; 类型 documentation) : 补充 --load-publish-endpoint 文档, 说明端口占用规模与显式地址放置方式, 是部署规划的依据。

关键符号: SchedulerLoadPublisher, publish_load_stat, LoadStat, _open_pub_socket, resolve_load_pub_range, parse_tcp_port, parse_advertisable_tcp, parse_bindable_tcp, is_kv_publisher_rank, init_load_publisher, publish_load_snapshot, check_load_publish_args

关键源码片段

[python/sglang/srt/managers/scheduler_components/load_publisher.py](#)

核心新组件: 定义 Wire 契约 LoadStat 与 SchedulerLoadPublisher 发布者, 含调用节流、去重心跳、HWM 语义与 best-effort 失败处理。

```
# 每个 scheduler 在独立 ZMQ PUB socket 上周期性发布 LoadStat 仪表值,
# 供进程外的 load-aware 路由器 (如 sgl-router 的 cache_aware_zmq 策略)
# 基于真实队列深度与 KV 占用做路由决策。帧格式与 KV 事件 socket 一致:
# [b"load", 大端 i64 seq, msgpack LoadStat], 订阅方一套循环处理两类消息。
```

```
from itertools import count
from typing import Optional

import msgspec
```

```

import zmq

# 除 force 外最多每 5 次调用发布一次；若被 DP 快照间隔覆盖则与其同相。
LOAD_PUBLISH_INTERVAL = 5

# 未变化的仪表值最多每 1 秒重发一次；变化值总是立即发出，
# 状态迁移永远不被延迟。约束 idle 自旋循环的发送速率。
LOAD_PUBLISH_HEARTBEAT_S = 1.0

# 小 HWM: load 是仪表值，管道满时丢弃的读数会被下一次心跳覆盖。
# ZMQ_CONFLATE（真正的 newest-wins）不可用——只保留单帧，
# 会破坏三帧帧格式——所以有界积压是最接近的折中。
LOAD_PUB_HWM = 8

_encoder = msgspec.msgpack.Encoder()

class LoadStat(msgspec.Struct, array_like=True, gc=False, tag=True):
    # Wire 形状 (tag + array_like) :
    # ["LoadStat", num_running_reqs, num_waiting_reqs, num_tokens,
    # max_total_num_tokens, attn_dp_rank]
    # 路由器按位置解码前四个计数；array_like 总是发射末尾字段
    # （未设置时为 null），解码方必须容忍。不设 omit_defaults:
    # 它可能裁掉末尾默认值，缩短路由器解码的形状。
    num_running_reqs: int
    num_waiting_reqs: int
    num_tokens: int # 在用的 KV tokens
    max_total_num_tokens: int # KV 容量；未知时为 0
    # DP attention 下为 attn_dp_rank，否则为普通 dp_rank;
    # 仅信息用途（路由器按 socket rank 主键）。命名跟随 EventBatch。
    attn_dp_rank: Optional[int] = None

def _open_pub_socket(endpoint: str) -> zmq.Socket:
    # 绑定 load PUB socket。模块级便于测试只 stub 这一处副作用，
    # 同时覆盖真实的 gating 与端口推导。不用 get_zmq_socket:
    # 它会设置 SNDHWM=0，破坏 LOAD_PUB_HWM 的语义。
    sock = zmq.Context.instance().socket(zmq.PUB)
    try:
        sock.set_hwm(LOAD_PUB_HWM)
        sock.setsockopt(zmq.LINGER, 0)
        if is_zmq_endpoint_ipv6(endpoint): # 来自 sglang.srt.utils.network
            sock.setsockopt(zmq.IPV6, 1)
        sock.bind(endpoint)
    except Exception:
        sock.close() # 不泄漏共享 context 上的句柄
        raise
    return sock

```

python/sglang/srt/disaggregation/kv_events.py

端口推导中枢：新增 is_kv_publisher_rank、parse_* 与 resolve_load_pub_range，绑定与广播共用同一 resolver，防止引擎广播自己不会绑定的范围。

```
# 广播为 /server_info 中的 load_topic; load socket 只承载 load,
# 订阅方可以 subscribe-all。
LOAD_TOPIC = 'load'
```

```
# PUB socket 可以 BIND 而非 CONNECT 的主机集合。按解析后的主机精确匹配
# 而非子串：":" 出现在每个 IPv6 地址内部，子串测试会把具体远端主机
# 误判为可绑定。
_BIND_WILDCARD_HOSTS = frozenset({'*', '0.0.0.0', '::'})
```

```
def parse_tcp_port(endpoint: Optional[str]) -> Optional[int]:
    # 与主机无关地回答 "tcp:// 端点占用哪个合法端口"，用于冲突检查
    # (replay ROUTER 可绑定任意主机拼写)。
    if not endpoint or not endpoint.startswith('tcp://'):
        return None
    try:
        port = NetworkAddress.parse(endpoint[len('tcp://'):]).port
    except ValueError:
        return None
    return port if 0 < port <= 65535 else None
```

```
def parse_advertisable_tcp(endpoint: Optional[str]) -> Optional[tuple[str, int]]:
    # 适合放进 /server_info 的 (host, port)，否则 None。任意主机都可
    # (KV 事件走 connect 风格)；IPv6 重新加括号，消费者可拼接
    # tcp://{host}:{port}。裸的无括号 IPv6 被拒绝——与 resolver 相同的
    # 解析，保证描述与绑定一致。
    if not endpoint or not endpoint.startswith('tcp://'):
        return None
    try:
        addr = NetworkAddress.parse(endpoint[len('tcp://'):])
    except ValueError:
        return None
    if not addr.host or not (0 < addr.port <= 65535):
        return None
    host = f'[{addr.host}]' if addr.is_ipv6 else addr.host
    return host, addr.port
```

```
def parse_bindable_tcp(endpoint: Optional[str]) -> Optional[tuple[str, int]]:
    # 如果 PUB socket 可以 BIND 该 tcp:// 端点则返回 (host, port),
    # 否则 None。具体主机在此是 connect 风格：load PUB 绑上去
    # 不会有人连接，而且不会报任何错误。
    if not endpoint or not endpoint.startswith('tcp://'):
```

```

    return None
try:
    addr = NetworkAddress.parse(endpoint[len('tcp://'):])
except ValueError:
    return None
if addr.host not in _BIND_WILDCARD_HOSTS or not (0 < addr.port <= 65535):
    return None
return addr.host, addr.port

```

python/sclang/srt/managers/scheduler.py

接线与快照复用：init_load_publisher 接线新组件，publish_load_snapshot 改为返回快照供发布者复用，stalled no-batch 路径发布负载并限流。

```

def publish_load_snapshot(self, force: bool = False):
    # 返回它发布的 LoadSnapshot；禁用、被节流或失败时返回 None——
    # 同址 sink（面向路由器的 load publisher）可复用该快照，
    # 避免再次遍历队列。这是对 override 点的破坏性变更：
    # 下游覆盖实现返回 None 仍功能正确，但会静默丢失共享快照优化。
    writer = self.load_snapshot_writer
    if writer is None:
        return None
    if not force:
        writer.publish_counter += 1
        if writer.publish_counter < writer.publish_interval:
            return None
    writer.publish_counter = 0
    try:
        load = self.load_inquirer.get_loads()
        writer.write(load)
        return load
    except Exception as e:
        logger.warning('load snapshot publish failed: %s', e)
        return None

```

评论区精华

PR 无行内 review 评论（review_comments 为 0），hzh0425 给出 APPROVED；讨论主要沉淀在 22 个 commit 的 review 迭代与 PR Notes 中：

- 端口推导必须单一来源（commit 66116dc）：首轮 review 要求把 load 端口推导收敛到 kv_events.py 的共享 helper，绑定与广播共用；auto 打包必须越过相邻 replay ROUTER 范围（replay = kv + 1 时总是冲突）。
- 去重心跳优于固定发布下限（commit 88841ea）：50ms 墙钟下限可能丢掉 busy→idle 迁移发布（最后一个 batch 的强制发布落在下限前微秒），路由器会看到最长约 1 秒的过期 busy 值；改为「未变化值按 1 秒心跳去重、变化值立即发」，迁移永不延迟。
- 与 #28599 方案收敛（commit 6c8ac210）：采纳并行 PR 中「严格更优」的部分——bindable 端点 resolver、显式 endpoint override、同步 socket，保留本 PR 的 Wire 契约与发布节奏。

- opt-in 是兼容性红线 (commit 4d3c29e) : 若默认开启, 任何 --kv-events-config 用户升级都会保留 kv_base + dp_size 端口, 可能撞掉同宿邻居未防护的 KV bind; 改为默认关闭后升级零影响。
- hzh0425 的 CI 失败提醒 (issue 评论) : 某次 CI 运行失败, 作者随后修复并 [/tag-and-rerun-ci](#) 重跑。
- load 端口推导收敛为单一 resolver, 并跳过 replay 范围 (design): 新增 resolve_load_pub_range, 绑定与广播统一走该函数; auto 模式在重叠时跳过 replay 范围。
- 去重心跳 vs 固定发布下限 (design): 采用 LOAD_PUBLISH_HEARTBEAT_S=1.0 去重心跳, 迁移发布永不延迟; 同时保留调用节流并在 dedup 命中后继续累计计数。
- 与 PR #28599 并行方案的收敛 (design): 完成方案合并, 形成最终的 resolve_load_pub_range / 显式 override / 同步 PUB 设计。
- 默认关闭以避免升级端口碰撞 (design): 特性改为 opt-in (--load-publish-endpoint), 默认不预留端口; 启动校验在入口拒绝重叠范围。
- publish_load_snapshot 返回快照的破坏性变更 (design): 两个调用点均把快照喂给 load publisher; 文档要求 override 返回所写快照以保留优化。
- stalled no-batch 路径的发布与限流 (performance): on_idle 在 fully-idle 门控前发布, 并引入 LOAD_STALL_REFRESH_S=0.05 墙钟下限约束两个 sink。

风险与影响

- 风险:
 1. 端口冲突 (启用时) : auto 模式每个 worker 从 KV base 起额外占用 $2 * dp_size$ 个端口 (相邻 replay 时为 $2 * dp_size + 1$), 同宿 worker 必须拉开 KV base 间距或改用显式地址; 这是 opt-in 而非默认开启的直接原因。
 2. 跨语言 Wire 契约未闭环: test_loadstat_golden_bytes 只钉死 Python 侧编码, Rust 路由器侧消费方尚未合入, 字段重排或改名在闭环前仍是静默跨语言破坏风险; 测试注释明确要求 Rust 侧断言同一 hex。
 3. 破坏性 override 变更: Scheduler.publish_load_snapshot 返回值从无变为 LoadSnapshot, 下游自定义 scheduler 若未同步返回快照, load socket 退化为自行遍历队列——功能正确但静默丢失共享快照优化。
 4. 严格端点解析的用户可见变更: 裸无括号 IPv6 KV 端点 (如 tcp://::1:5557) 会使 /server_info 整体丢弃 kv_events 块, 旧逻辑会广播一个不可用地址; 依赖旧行为的部署需改写为 tcp://[::1]:5557。
 5. 热路径新增逻辑: 发布路径在每个调度循环运行, 失败日志按 episode 限流; 默认关闭时每个 batch 仅一次 bound method 加 None 检查; stalled 自旋路径由 50ms 墙钟下限约束 get_loads, 避免放大 $O(queue)$ 开销。
- 影响:
 1. 用户与部署: 默认零影响; 启用后为 sgl-router 提供真实负载源, 但端口占用需纳入部署规划; 裸 IPv6 KV 端点用户面临有意的行为变更。
 2. 系统: 调度器新增一个可选 PUB socket 与发布逻辑, 与 DP 均衡 sink 共享快照避免重复遍历, stalled 路径获得 50ms 级负载刷新。

3. 团队：为该功能线定义了跨语言 Wire 契约（msgpack 形状、帧格式、golden 测试方法），后续 router PR 需对齐；server args 表格新增参数，observability 命名空间继续扩充；多人协作痕迹明显（hzh0425 合入 main 分支并修复 server arg，最终审批），属于团队共同维护的重点特性（带 high priority 标签）。 - 风险标记：热路径新增发布逻辑，跨语言 Wire 契约未闭环，端口占用规划，破坏性 override 变更，默认关闭的 opt-in 特性，严格端点解析变更

关联脉络

- PR #28599 Per-scheduler load publisher（并行方案，提交中提及）：commit 6c8ac210 明确「采纳 #28599 中严格更优的部分」（bindable 端点 resolver、显式 override、同步 socket），与本 PR 属于同一功能线的并行方案收敛。
- PR #36586 [Core] Refactor server argument choices: 同期重构 server_args.py 参数注册与校验路径，与本 PR 新增的 --load-publish-endpoint / check_load_publish_args 处于同一耦合面。
- PR #36681 Move server args config parser under utils: server_args.py 解析器迁移至 utils/server_args_config_parser.py，本 PR 的启动校验依赖同一套参数基础设施，后续迁移需随迁。