

PR #33595 完整报告

sgl-project/sglang

Measure prefill busy time between launches

合并时间: 2026-08-06 02:26

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/33595>

执行摘要

- 一句话: 改为 launch 间隔统计 prefill/decode 忙时, 统一负载指标
- 推荐动作: 值得精读, 虽然改动量不大, 但它是调度器负载统计口径的一次重要统一设计。可以重点关注 `_record_step_counters` 中样本过滤条件的组合, 以及 `after_idle_gap` 标记在重叠事件循环中的传递路径。建议后续补充针对边界条件的单元测试, 以保护该统计逻辑的稳定性。

功能与动机

PR body 明确指出: Prefill busy time currently spans from batch launch until result processing. Under scheduler overlap, that includes unrelated CPU scheduling work and makes prefill accounting inconsistent with the existing launch-to-launch decode metric. 因此需要将 prefill 统计改为与 decode 相同的 launch 间隔口径, 保证 autoscale 等负载判断一致性。

实现拆解

1. 数据模型扩展: 在 `ScheduleBatch` 类中新增 `after_idle_gap: bool = False` 字段, 并在 `copy()` 方法中透传该字段, 用于标记当前批次是否为调度器空闲后的首个批次。
2. 调度器状态追踪: 在 `Scheduler` 中, 将原有的 `_prev_decode_launch_ts` 替换为 `_prev_step: Optional[Tuple[int, float, bool]]`, 保存上一次的前向迭代号、launch 时间戳和 prefill 标志; 同时在 `init_load_inquirer` 中新增 `_sched_idled = False` 状态, 并在 `event_loop_normal` 与 `event_loop_overlap` 中, 当批次为空时 (`batch is None`) 置位 `_sched_idled = True`。
3. launch 入口标记: `run_batch` 中在记录 `launch_ts` 后, 将 `_sched_idled` 写入 `batch.after_idle_gap`, 然后立即复位 `_sched_idled = False`, 从而让后续的统计逻辑感知到 idle 空档。
4. 统计逻辑重写: `_record_step_counters` 改为基于 `_prev_step` 与当前批次的 launch 时间戳计算间隔 `step_us`, 并依次丢弃四类无效样本: 无前置记录、`after_idle_gap` 为真、前后迭代号不连续、prefill/decode 模式切换; 在合法区间 $0 < \text{step_us} < \text{STEP_MAX_US}$ 内, prefill 累加 `total_prefill_busy_us`, decode 调用 `_accumulate_decode_moment`。
5. 常量和测试配套: 将 `DECODE_STEP_MAX_US` 重命名为 `STEP_MAX_US` 以覆盖两种统计; 第二个提交删除了原来针对 step counter 的单元测试, 因此该改动目前没有新增自动化

测试覆盖。

关键文件：

- python/sglang/srt/managers/scheduler.py (模块 调度器；类别 source；类型 core-logic；符号 `_record_step_counters`, `_prev_step`, `_sched_idled`, `run_batch`)：核心统计逻辑所在文件，包含 `_record_step_counters` 重写、`_prev_step` 状态引入、`_sched_idled` 标记以及常量重命名。
- python/sglang/srt/managers/schedule_batch.py (模块 调度器；类别 source；类型 core-logic；符号 `ScheduleBatch.after_idle_gap`, `ScheduleBatch.copy`)：为 `ScheduleBatch` 新增 `after_idle_gap` 字段并在 `copy()` 中透传，是统计逻辑传递 idle 状态的关键数据通路。

关键符号：`_record_step_counters`, `run_batch`, `init_load_inquirer`, `ScheduleBatch.copy`

关键源码片段

python/sglang/srt/managers/scheduler.py

核心统计逻辑所在文件，包含 `_record_step_counters` 重写、`_prev_step` 状态引入、`_sched_idled` 标记以及常量重命名。

```
# _record_step_counters 核心统计逻辑（重新整理）
def _record_step_counters(self, batch, result):
    # 健康检查请求不参与负载统计，直接返回
    if all(is_health_check_generate_req(req) for req in batch.reqs):
        return

    # 根据 forward_mode 判断当前批次是否为 prefill
    is_prefill = batch.forward_mode.is_prefill()
    prev = self._prev_step
    # 先记录当前步，之后再用旧值计算间隔
    self._prev_step = (batch.forward_iter, batch.launch_ts, is_prefill)

    # 丢弃无前置记录、idle 空档后的首个批次
    if prev is None or batch.after_idle_gap:
        return

    prev_iter, prev_ts, prev_is_prefill = prev
    # 丢弃 forward 迭代不连续（如插入其他 batch 或跳步）以及模式切换的样本
    if prev_iter + 1 != batch.forward_iter or prev_is_prefill != is_prefill:
        return

    # 相邻两次 launch 的时间间隔（微秒），这里才是真正的忙时口径
    step_us = int((batch.launch_ts - prev_ts) * 1e6)
    # 丢弃非法时长，避免时钟异常或过大间隔污染统计
    if not 0 < step_us < STEP_MAX_US:
        return

    if is_prefill:
```

```

        self.total_prefill_busy_us += step_us
        self.total_prefill_uncached_tokens += batch.extend_num_tokens
    else:
        # decode 沿用原有动量累积，但间隔也改为 launch-to-launch
        _accumulate_decode_moment(
            self.decode_moment_totals,
            len(batch.reqs),
            step_us,
            len(batch.reqs) + result.num_correct_drafts,
        )

```

python/sglang/srt/managers/schedule_batch.py

为 `ScheduleBatch` 新增 `after_idle_gap` 字段并在 `copy()` 中透传，是统计逻辑传递 idle 状态的关键数据通路。

ScheduleBatch 中新增的字段定义（节选）

```

class ScheduleBatch(...):
    # ... 其他字段 ...
    # Metrics
    dp_cooperation_info: Optional[DPCooperationInfo] = None
    prefill_stats: Optional[PrefillStats] = None
    forward_iter: Optional[int] = None
    launch_ts: Optional[float] = None
    # 标记当前批次是否紧跟在调度器空闲之后，用于统计时丢弃跨 idle 的样本
    after_idle_gap: bool = False

    def copy(self):
        # ... 其他参数 ...
        return ScheduleBatch(
            # ... 其余构造参数 ...
            forward_iter=self.forward_iter,
            launch_ts=self.launch_ts,
            after_idle_gap=self.after_idle_gap,
            extend_num_tokens=self.extend_num_tokens,
        )

```

评论区精华

该 PR 没有公开的 review 评论或讨论线程，仅有两次 `/tag-and-rerun-ci` 触发 CI 的指令。作者在 PR body 中说明此变更只影响调度器指标记账，不影响模型输出，因此未提供测试和性能数据。

- 暂无高价值评论线程

风险与影响

- 风险：风险主要在于统计口径变更可能影响 autoscale 等依赖负载指标的功能：
 1. `_prev_step` 只在连续同模式批次间累积，若长期 idle 或频繁模式切换，样本量可能减少，导致忙时估算偏低；

2. `after_idle_gap` 标记依赖 `run_batch` 入口，`prebuilt batch` 等提前返回路径是否同样设置尚未验证；
 3. 该 PR 明确没有单元测试覆盖，`_record_step_counters` 的边界条件（如 `forward_iter` 不连续、时长阈值）缺少回归保护。但这些风险仅影响指标统计精度，不直接影响模型推理正确性。
- 影响：影响范围集中在调度器内部的负载统计模块，涉及 `scheduler.py` 和 `schedule_batch.py` 两个文件。用户可见行为无变化，但 `autoscale` 和负载监控相关的下游逻辑可能观察到不同的 `prefill busy` 时间数值。对团队而言，后续在 `overlap` 调度下需要重新校准基于该指标设置的阈值。
 - 风险标记：核心调度指标变更，缺少单元测试覆盖

关联脉络

- PR #33403 [Scheduler] Honor explicit min-free-slots thresholds: 同为调度器负载控制相关改动，修改了 `min-free-slots` 延迟器的阈值逻辑，与本次 `load metrics` 统计口径调整共同影响调度器的负载判断和 `autoscale` 行为。