

PR #29406 完整报告

sgl-project/sglang

Stop reading `cur_batch` in `is_fully_idle` and `abort_request`

合并时间: 2026-07-10 08:54

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29406>

执行摘要

- 一句话: 消除调度器中 `cur_batch` 的非必要读取
- 推荐动作: 建议快速合入。本 PR 变更量小 (4 行新增, 5 行删除), 每一步都附带了等价性证明和有意的行为变更说明。审核机器人提出的正确性担忧已被 PR 设计解决。对于关注调度器架构和状态管理的工程师, 本 PR 展示了一个很好的增量式重构案例——通过逐步建立不变式来安全地清理字段依赖。

功能与动机

该 PR 是调度器状态字段局部化重构系列的一部分。其根本动机是消除对 `self.cur_batch` 的外部读取, 使得 `cur_batch` 可以成为仅调度器内部使用的局部变量, 从而减少不依赖传递和错误访问。PR body 明确指出: "This PR removes every load-bearing read of `self.cur_batch` outside the PP microbatch slot arrays", 并且 "lets a following PR localize the field cleanly"。

实现拆解

本 PR 通过三步完成对 `self.cur_batch` 读取的移除:

1. 语法拒绝请求直接标记完成 (行为有意变更): 在 `scheduler_components/batch_result_processor.py` 中, `_apply_prefill_grammar` 和 `_accept_grammar_tokens` 两个方法在语法拒绝时不调用 `self.abort_request(AbortReq(rid=req.rid))`, 而是直接设置 `req.to_finish = FINISH_ABORT()`。这是唯一在迭代中期 (`process_batch_result` 内部) 调用 `abort_request` 的地方, 移除它建立了后续步骤所需的不变式。同时修复了旧代码中因 `rid` 前缀匹配导致意外终止其他请求的 bug。
2. `abort_request` 改用 `last_batch`: 在 `scheduler.py` 的 `abort_request` 方法中, 非 `pipeline-parallel` 模式下扫描运行中请求的列表从 `[self.running_batch, self.cur_batch]` 改为 `[self.running_batch, self.last_batch]`。根据第一步建立的不变式 (`abort_request` 仅在事件循环顶部被调用), 此时 `cur_batch` 和 `last_batch` 等价 (或均为 `None`), 因此行为等价。
3. `is_fully_idle` 移除冗余的 `cur_batch` 项: 从 `is_fully_idle` 的 `idle` 条件中删除了 `(self.cur_batch is None or self.cur_batch.is_empty())`。该条件在 PP 模式下是 `_pp_microbatches_drained()` 的子集, 在非 PP 模式下则与已存在的 `last_batch` 条件重复。

测试配套: 本次变更未包含专门的测试文件修改。

关键文件：

- python/sglang/srt/managers/scheduler_components/batch_result_processor.py（模块调度器；类别 source；类型 core-logic；符号 _apply_prefill_grammar, _accept_grammar_tokens）：核心变更文件：将语法拒绝时的 abort_request 调用替换为直接设置 req.to_finish，这是建立 invariant 的关键。同时修正了因 rid 前缀匹配导致误中止其他请求的 bug。
- python/sglang/srt/managers/scheduler.py（模块调度器；类别 source；类型 core-logic；符号 is_fully_idle, abort_request）：次要变更文件：在 is_fully_idle 中删除 cur_batch 检查，在 abort_request 中将 cur_batch 替换为 last_batch。

关键符号：_apply_prefill_grammar, _accept_grammar_tokens, is_fully_idle, abort_request

关键源码片段

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

核心变更文件：将语法拒绝时的 abort_request 调用替换为直接设置 req.to_finish，这是建立 invariant 的关键。同时修正了因 rid 前缀匹配导致误中止其他请求的 bug。

```
# File: python/sglang/srt/managers/scheduler_components/batch_result_processor.py
```

```
from sglang.srt.disaggregation.utils import DisaggregationMode
from sglang.srt.env import envs
from sglang.srt.layers.logits_processor import LogitsProcessorOutput
# 移除了对 AbortReq 的导入
# from sglang.srt.managers.io_struct import AbortReq
from sglang.srt.managers.schedule_batch import (
    FINISH_ABORT, # 新增导入：用于直接标记请求终止
    Req,
    ScheduleBatch,
)
# ... 省略无关代码 ...
```

```
class BatchResultProcessor:
    # ...
```

```
def _apply_prefill_grammar(self, *, req: Req, next_token_id: int) -> None:
    # FIXME: this try-except block is for handling unexpected xgrammar issue.
    try:
        req.grammar.accept_token(next_token_id)
    except ValueError as e:
        # Grammar accept_token can raise ValueError if the token is not in the grammar.
        # This can happen if the grammar is not set correctly or the token is invalid.
        logger.error(
            f"Grammar accept_token failed for req {req.rid} with token {next_token_id}: {e}"
        )
```

```

        # 旧代码: self.abort_request(AbortReq(rid=req.rid))
        # 新代码: 直接标记请求为终止, 避免通过 rid 扫描所有队列 / 批次
        req.to_finish = FINISH_ABORT()
        req.grammar.finished = req.finished()

def _accept_grammar_tokens(
    self, req: Req, tokens: Union[int, List[int]]
) -> List[int]:
    """Advance the grammar over the accepted token(s), stopping at the token
    that terminates it.
    ...
    """
    if isinstance(tokens, int):
        tokens = [tokens]
    retained = []
    try:
        for token_id in tokens:
            req.grammar.accept_token(token_id)
            retained.append(token_id)
            if req.grammar.is_terminated():
                break
    except ValueError as e:
        logger.error(
            f"Grammar accept_token failed for req {req.rid} with token "
            f"{tokens}: {e}"
        )
    # 同样的改动: 直接标记终止, 而非调用 abort_request
    req.to_finish = FINISH_ABORT()
    return retained

```

python/sglang/srt/managers/scheduler.py

次要变更文件: 在 `is_fully_idle` 中删除 `cur_batch` 检查, 在 `abort_request` 中将 `cur_batch` 替换为 `last_batch`。

File: python/sglang/srt/managers/scheduler.py

```

class Scheduler:
    # ...

def is_fully_idle(self, for_health_check=False) -> bool:
    # ...
    # Batch running status
    idle = (
        self.running_batch.is_empty()
        and self.chunked_req is None
        and not self.dlrm_manager.any_staging_reqs()
        and (self.last_batch is None or self.last_batch.is_empty())
        # 旧代码: and (self.cur_batch is None or self.cur_batch.is_empty())
        # 新代码: 移除了 cur_batch 项, 因为 last_batch 已覆盖相同语义
    )

```

```

        and (not self.enable_overlap or len(self.result_queue) == 0)
        and self._pp_microbatches_drained()
    )
    # ...

def abort_request(self, recv_req: AbortReq):
    # ...
    # Delete requests in the running batch
    if self.ps.pp_size == 1:
        # 旧代码: inflight_batches = [self.running_batch, self.cur_batch]
        # 新代码: 使用 last_batch 替代 cur_batch
        # 注: 此时 abort_request 仅在事件循环顶部被调用, cur_batch == last_batch
        inflight_batches = [self.running_batch, self.last_batch]
    else:
        inflight_batches = [*self.running_mbs, *self.mbs]
    # ...

```

评论区精华

审核机器人 `gemini-code-assist[bot]` 在 `abort_request` 的改动上提出了严重正确性担忧，认为将 `self.cur_batch` 替换为 `self.last_batch` 会引入 bug。其论据是：当 `abort_request` 在 `process_batch_result` 期间同步调用时（如语法拒绝场景），请求只存在于 `cur_batch` 中，而此时 `last_batch` 尚未更新，因此扫描 `last_batch` 会找不到该请求。

然而该评论忽略了 PR 中第一步变更：语法拒绝场景已经不再调用 `abort_request`，而是直接设置 `req.to_finish`。因此 `abort_request` 不会再在 `process_batch_result` 内部被调用，建立了 PR body 中所述的不变式。该评论虽然正确指出了理论风险，但实际已被 PR 的第一步解决。作者在 PR body 中已明确阐述了这一步的意图和等价性证明。

- 将 `cur_batch` 替换为 `last_batch` 可能导致正确性 bug (correctness): 该担忧已被 PR 的第一步变更解决：语法拒绝场景不再调用 `abort_request`，而是直接设置 `req.to_finish = FINISH_ABORT()`。因此 `abort_request` 永远不会在 `process_batch_result` 内部被调用，`cur_batch` 和 `last_batch` 在 `abort_request` 调用时总是等价的。

风险与影响

- 风险：本 PR 存在以下技术风险：
 1. 正确性风险（低）：如果在未来的重构中意外引入新的 `abort_request` 在迭代中期调用的场景，而 `cur_batch` 已被移除，则可能无法正确中止请求。此风险已被 PR body 中明确的不变式声明和 Codex 审计结果缓解。
 2. 回归风险（中）：`is_fully_idle` 的变更虽然理论上行为等价，但 `cur_batch` 和 `last_batch` 在不同步时钟点（如 `process_batch_result` 刚执行完但尚未更新 `last_batch` 时）可能有短暂差异。然而 `idle` 检查通常只在调度循环开始时调用，实际影响很小。
 3. 测试覆盖缺失：PR 没有新增测试来验证新行为（尤其是第一步的有意变更——不再误杀前缀匹配的请求），回归风险更多依赖于代码审查而非自动化测试。- 影响：影响范围：仅影响调度器（Scheduler）的两个方法：`is_fully_idle` 和 `abort_request`。对外部 API、

推理性能、用户可见行为无直接影响。影响程度：低。变更后的行为在大多数场景下与之前完全一致，仅在语法拒绝场景下行为有细微差异（不再误终止前缀匹配的其他请求），这实际上是一个 bugfix。团队影响：为后续将 `cur_batch` 局部化的重构扫清了障碍，有利于代码可维护性和状态清晰度。

- 风险标记：缺乏测试覆盖，核心路径变更

关联脉络

- PR #29407 Localize `cur_batch` field in Scheduler to avoid field-based state access: 这是本 PR 的后续工作，利用本 PR 建立的不变式将 `cur_batch` 字段局部化，仅看门狗使用。
- PR #29408 Avoid implicit field-based side channel in Scheduler planning: 与本 PR 同属调度器状态重构系列，消除隐式副作用通道，进一步减少不必要的字段依赖。
- PR #30573 Configurable decode retraction order: 修改了 `schedule_batch.py`，与本 PR 的调度器重构同属调度相关变更。