

PR #29217 完整报告

sgl-project/sglang

[MLX] Fix step-bounded profiling for bench tools on Apple Silicon

合并时间: 2026-07-01 13:55

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29217>

执行摘要

- 一句话: 修复 MLX 后端步长限制分析无法自动停止的问题
- 推荐动作: 值得精读。该 PR 展示了在非标准调度路径中准确插桩 profiling 钩子的模式, 以及如何通过幂等设计提高 CLI 工具的健壮性。对于维护 MLX 后端或类似定制调度逻辑的开发者有直接参考价值。

功能与动机

PR #29217 是 Apple 设备支持路线图 (#19137) Profiling 部分的后续。在 MLX 后端, `bench_offline_throughput`、`bench_one_batch_server` 和 `bench_serving` 无法产出可用的 Metal trace: step-bounded profiling 从不自动停止, 导致 GPU 捕获整个生成过程, 在 `MTL_CAPTURE_ENABLED=1` 下更慢, 最终调度器 watchdog (300s) 超时 SIGQUIT 杀掉服务器。根原因是 MLX overlap loop (`event_loop_overlap_mlx`) 跳过了 `Scheduler.run_batch()`, 而 `forward_ct` 递增和 profiler predicate 调用恰在 `run_batch` 中, 导致 `forward_ct` 始终为 0, profiler 的 step 条件无法满足, watchdog 也因 liveness 计数器不更新而误判。

实现拆解

1. 在 MLX 重叠调度关键路径添加 profiler 支持: 在 `python/sglang/srt/hardware_backend/mlx/scheduler_mixin.py` 的 `_finalize_mlx_pending_job` 方法开头增加 `self.forward_ct += 1` 和 `self.profiler_manager._profile_batch_predicate(pending.schedule_batch)`, 模拟 `run_batch()` 中的行为。
2. 使 bench 工具 stop_profile 幂等: 在 `python/sglang/benchmark/offline_throughput.py` 中, 将直接调用 `backend.stop_profile()` 替换为 `try: backend.stop_profile() except RuntimeError: pass`, 以兼容调度器自动停止后再次调用的情况。
3. 新增单元测试: 新增 `test/registered/unit/hardware_backend/mlx/test_scheduler_mixin.py`, 覆盖 `forward_ct` 递增和 profiler predicate 调用, 验证每次 job finalize 恰好对应一次计数和一次 predicate, 且 `process_batch_result` 仍正常执行。

关键文件:

- `python/sglang/srt/hardware_backend/mlx/scheduler_mixin.py` (模块 MLX 调度器; 类别 source; 类型 core-logic; 符号 `SchedulerMlxOverlapMixin._finalize_mlx_pending_job`): 核心修复: 在 `_finalize_mlx_pending_job` 中添加 `forward_ct` 递增和 profiler predicate

调用，使 step-bounded profiling 在 MLX 重叠循环中生效。

- `python/sglang/benchmark/offline_throughput.py`（模块 基准工具；类别 source；类型 core-logic）：为 `stop_profile` 添加幂等处理，防止调度器已自动停止后再次调用抛异常。
- `test/registered/unit/hardware_backend/mlx/test_scheduler_mixin.py`（模块 测试；类别 test；类型 test-coverage；符号 `TestFinalizeMlxPendingJob`, `_make_scheduler`, `test_finalize_advances_forward_ct_and_runs_predicate`, `test_forward_ct_advances_once_per_step`）：新增单元测试，验证 `forward_ct` 递增和 profiler predicate 调用，防止回归。

关键符号：`SchedulerMlxOverlapMixin._finalize_mlx_pending_job`

关键源码片段

`python/sglang/srt/hardware_backend/mlx/scheduler_mixin.py`

核心修复：在 `_finalize_mlx_pending_job` 中添加 `forward_ct` 递增和 profiler predicate 调用，使 step-bounded profiling 在 MLX 重叠循环中生效。

```
def _finalize_mlx_pending_job(self: Scheduler, pending: MlxPendingJob):
    # 前进 forward_ct 并触发 profiler 批处理谓词；
    # 标准调度器在 run_batch 中做这些，但 MLX 重叠循环绕过 run_batch，
    # 因此在此处手动补齐，使得 step-bounded profiling 能自动停止。
    self.forward_ct += 1
    self.profiler_manager._profile_batch_predicate(pending.schedule_batch)

    # 原有 finalize 逻辑保持不变
    result = self.tp_worker.finalize_mlx_result(
        pending.prefills, pending.extends,
        pending.decode, pending.mode, pending.reqs,
    )
    if result.next_token_ids is not None:
        pending.batch_copy.input_ids = result.next_token_ids
        pending.schedule_batch.input_ids = result.next_token_ids
    self.last_batch = pending.schedule_batch
    self.process_batch_result(pending.batch_copy, result)
```

`python/sglang/benchmark/offline_throughput.py`

为 `stop_profile` 添加幂等处理，防止调度器已自动停止后再次调用抛异常。

```
if profile:
    dir = os.getenv("SGLANG_TORCH_PROFILER_DIR")
    if not profile_steps:
        known_files = set(os.listdir(dir))
        # 当 --profile-steps 指定步数时，调度器会在 N 步后自动停止；
        # 此时再调 stop_profile 会抛 "not in progress" RuntimeError。
        # 短于 N 步的 runs 未达目标，仍需显式停止。
        # 无论如何，stop 必须在 monitor_trace_file 之前完成。
    try:
        backend.stop_profile()
```

```
except RuntimeError:
    pass
monitor_trace_file(known_files, dir)
```

test/registered/unit/hardware_backend/mlx/test_scheduler_mixin.py

新增单元测试，验证 forward_ct 递增和 profiler predicate 调用，防止回归。

```
def test_finalize_advances_forward_ct_and_runs_predicate(self):
    from sglang.srt.hardware_backend.mlx.scheduler_mixin import (
        SchedulerMlxOverlapMixin,
    )
    scheduler = self._make_scheduler()
    pending = MagicMock()
    SchedulerMlxOverlapMixin._finalize_mlx_pending_job(scheduler, pending)
    # forward_ct 应从 0 变为 1
    self.assertEqual(scheduler.forward_ct, 1)
    # profiler 批处理谓词应被调用一次
    scheduler.profiler_manager._profile_batch_predicate.assert_called_once_with(
        pending.schedule_batch
    )
    # 原有 finalize 流程仍正常执行
    scheduler.process_batch_result.assert_called_once()

def test_forward_ct_advances_once_per_step(self):
    # 连续调用三次，验证 forward_ct 每次递增 1，数量匹配
```

评论区精华

Reviewer jlee5814 指出：当 --profile-steps N 指定的步数超过实际生成步数时，monitor_trace_file 会无限循环等待，建议将 stop_profile 调用包裹为幂等。作者随后修改，添加 try/except RuntimeError。该提议被接纳并合并。

- stop_profile 幂等性需求 (correctness): 作者添加 try/except RuntimeError 实现幂等，被接受。

风险与影响

- 风险：变更仅影响 MLX 后端且 profiling 启用时，正常推理不受影响。新代码引入的整数递增和方法调用开销可忽略 ($O(1)$)。风险点在于 self.profiler_manager 在 mixin 中是否确保初始化；单元测试通过 MagicMock 验证了调用，但在实际调度器中可能因缺失属性导致 AttributeError。不过 profiler_manager 在 Scheduler 基类中已有默认初始化，因此风险低。
- 影响：用户影响：Apple Silicon 上使用 MLX 后端的开发者，现在可以通过 --profile-steps 正常进行 step-bounded profiling，获得可用的 .gputrace 文件，且不再因 watchdog 超时而崩溃。系统影响：无性能退化，因 forward_ct 递增和空 predicate 不在标准路径上。团队影响：为后续 MLX 性能分析 workflow 铺平道路，减少调试 profiling 工具的时间。
- 风险标记：MLX 后端变更，步长分析修复，幂等设计

关联脉络

- PR #28122 [MLX] Add Metal profiling hooks to server profiler: 为本 PR 的前置工作，添加了 Metal profiling 后端钩子。本 PR 在其基础上修复 step-bounded 自动停止。
- PR #19137 [Roadmap] Apple Device Support (2026 Q2): PR #29217 属于该路线图 Profiling 部分的实现，目标是在 Apple Silicon 上完整支持 sglang。