

PR #32447 完整报告

sgl-project/sglang

[MLX] Fix overlap-loop request bookkeeping and graceful shutdown

合并时间: 2026-07-29 10:04

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/32447>

执行摘要

- 一句话: 修复 MLX overlap 调度器首请求崩溃与优雅退出
- 推荐动作: 该 PR 修复了 MLX 后端两个隐蔽但影响严重的问题, 值得相关开发者精读, 尤其是 `_prepare_mlx_launch` 的设计及其与 `run_batch` 的对齐方式, 以及优雅退出的处理。Review 讨论中对 `launch_ts` 放置位置和 SWA 维护的权衡也值得参考。

功能与动机

引用 Issue #32445 描述: MLX overlap 调度循环绕过 `Scheduler.run_batch`, 但 `run_batch` 会 stamp `batch.launch_ts` 并递增 `forward_ct`。 `process_batch_result -> _record_step_counters` 无条件地使用 `launch_ts`, 若为 `None` 则引发 `TypeError`, 导致调度器崩溃。健康检查请求被排除在计数器外, 因此 `/health_generate` 仍显示绿色, 而真实请求全部失败。同时, `event_loop_overlap_mlx` 未检查 `self.gracefully_exit`, 导致关闭信号无法使循环退出, 最终超时后被强制杀进程, 无法释放用户态资源。

实现拆解

1. 新增 `_prepare_mlx_launch` 方法: 在文件 `scheduler_mixin.py` 的 `SchedulerMlxOverlapMixin` 中新增该方法, 递增 `forward_ct`, 为 `batch` 设置 `forward_iter` 和 `launch_ts`, 并调用 `_profile_batch_predicate`。该方法在每次 MLX 发射前调用, 等同于 `run_batch` 的启动会计。
2. 修改发射路径: 在 `_launch_fresh` 和 `_launch_chained` 中, 在调用 `resolve_forward_inputs` 或 `async_chained_decode_mlx` 之前调用 `_prepare_mlx_launch`, 确保时间戳在异步图构建前记录。`_launch_chained` 中仅保留 `forward_iter` 更新 (用于 SWA 维护), 删除 `launch_ts` 重复赋值以与 `run_batch` 行为对齐。
3. 简化 `_finalize_mlx_pending_job`: 移除原有的 `forward_ct` 递增和 profiler 调用 (已迁移至发射前), 使其仅专注于调用 `finalize_mlx_result` 并处理结果。这避免了重复计数。
4. 添加优雅退出支持: 在 `event_loop_overlap_mlx` 的 `while` 循环顶部增加 `if self.gracefully_exit: break`, 并在 `break` 前调用 `mx.synchronize()` 以确保所有已提交的异步 Metal 工作完成, 避免在资源释放时出现异常。
5. 测试重构: 将 `test_scheduler_mixin.py` 中的 `TestFinalizeMlxPendingJob` 类重写为 `TestMlxLaunchBookkeeping`, 覆盖 `_prepare_mlx_launch` 的正确性 (`forward_ct` 递增、`forward_iter` 和 `launch_ts` 类型、profiler 调用)。新增

TestOverlapLoopStampsLaunchTs 集成测试，使用真实 event_loop_overlap_mlx 循环验证新鲜发射和链式发射均能正确 stamp launch_ts。调整 test_attention_patching.py 中的测试，移除对 forward_ct 的严格断言（因计数已移至发射阶段），并添加 gracefully_exit 和 forward_ct 初始化。

关键文件：

- python/sglang/srt/hardware_backend/mlx/scheduler_mixin.py（模块 MLX 后端；类别 source；类型 core-logic；符号 _prepare_mlx_launch, _finalize_mlx_pending_job, event_loop_overlap_mlx）：核心源码文件，修复了 MLX overlap 调度器的记账和退出逻辑。新增 _prepare_mlx_launch 方法，重构 _finalize_mlx_pending_job，修改 _launch_fresh 和 _launch_chained，在 event_loop_overlap_mlx 中添加 graceful exit 检查和 mx.synchronize。
- test/registered/unit/hardware_backend/mlx/test_scheduler_mixin.py（模块 测试（MLX）；类别 test；类型 test-coverage；符号 TestMlxLaunchBookkeeping, TestOverlapLoopStampsLaunchTs, test_prepare_launch_advances_forward_ct_and_runs_predicate, test_forward_ct_advances_once_per_launch）：测试文件，几乎完全重写，提供对 _prepare_mlx_launch 的单元测试和集成测试，确保新记账行为正确，并验证优雅退出路径。
- test/registered/unit/hardware_backend/mlx/test_attention_patching.py（模块 测试（Attention）；类别 test；类型 test-coverage；符号 test_finalize_pending_job_updates_scheduler_last_batch, test_overlap_loop_materializes_prefill_input_ids, FakeOverlapScheduler）：辅助测试调整，删除已不再适用的 forward_ct 断言，添加 graceful_exit 和 forward_ct 初始化，以便与新的记账模型兼容。

关键符号：_prepare_mlx_launch, _finalize_mlx_pending_job, _launch_fresh, _launch_chained, event_loop_overlap_mlx, TestMlxLaunchBookkeeping._make_scheduler, TestMlxLaunchBookkeeping.test_prepare_launch_advances_forward_ct_and_runs_predicate, TestMlxLaunchBookkeeping.test_forward_ct_advances_once_per_launch, TestMlxLaunchBookkeeping.test_finalize_does_not_double_count_launch, TestOverlapLoopStampsLaunchTs.test_fresh_launch_stamps_launch_ts_before_input_materialization, TestOverlapLoopStampsLaunchTs.test_chained_launch_re_stamps_forward_iter_and_profiler

关键源码片段

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

核心源码文件，修复了 MLX overlap 调度器的记账和退出逻辑。新增 _prepare_mlx_launch 方法，重构 _finalize_mlx_pending_job，修改 _launch_fresh 和 _launch_chained，在 event_loop_overlap_mlx 中添加 graceful exit 检查和 mx.synchronize。

```
def _prepare_mlx_launch(self: Scheduler, batch: ScheduleBatch):
    """在 MLX 发射前 stamp 调度器记账字段。"""
    # 与 run_batch 的发射边界对齐。特别是 profiler 谓词
    # 必须在图构建 / mx.async_eval 之前运行；如果在 finalize
```

```

# 阶段运行，会导致至少多 profile 一个已排队的 decode 步骤。
self.forward_ct += 1
batch.forward_iter = self.forward_ct
batch.launch_ts = time.monotonic()
self.profiler_manager._profile_batch_predicate(batch)

def _finalize_mlx_pending_job(self: Scheduler, pending: MlxPendingJob):
    # 移除了 forward_ct 递增和 profiler 调用，这些已移至发射前。
    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)

def event_loop_overlap_mlx(self: Scheduler):
    ...
    while True:
        # 优雅退出检查：必须排在任何 pause 逻辑之前
        if self.gracefully_exit:
            # synchronize 确保所有异步 Metal 工作已完成
            mx.synchronize()
            break
        if self._engine_paused:
            ...
        # 其余循环逻辑 ...

```

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

测试文件，几乎完全重写，提供对 `_prepare_mlx_launch` 的单元测试和集成测试，确保新记账行为正确，并验证优雅退出路径。

```

class TestMlxLaunchBookkeeping(unittest.TestCase):
    """run_batch 风格的记账检测：MLX overlap 循环必须正确 stamp 发射边界。"""

    def _make_scheduler(self):
        scheduler = MagicMock()
        scheduler.forward_ct = 0
        result = MagicMock()
        result.next_token_ids = None
        scheduler.tp_worker.finalize_mlx_result.return_value = result
        return scheduler

    def test_prepare_launch_advances_forward_ct_and_runs_predicate(self):

```

```

from sglang.srt.hardware_backend.mlx.scheduler_mixin import (
    SchedulerMlxOverlapMixin,
)
scheduler = self._make_scheduler()
batch = MagicMock()

SchedulerMlxOverlapMixin._prepare_mlx_launch(scheduler, batch)

# forward_ct 递增
self.assertEqual(scheduler.forward_ct, 1)
# batch 上 stamp forward_iter
self.assertEqual(batch.forward_iter, 1)
# launch_ts 是 float (时间戳)
self.assertIsInstance(batch.launch_ts, float)
# profiler 谓词已调用
scheduler.profiler_manager._profile_batch_predicate.assert_called_once_with(batch)

def test_forward_ct_advances_once_per_launch(self):
    # 连续调用三次 forward_ct 依次为 1,2,3
    ...

def test_finalize_does_not_double_count_launch(self):
    # 先 launch 后 finalize, forward_ct 仍为 1
    ...

```

评论区精华

- `launch_ts` 放置顺序: reviewer yeahdongcn 指出 `_launch_fresh` 中 `launch_ts` 在 `resolve_forward_inputs` 之后赋值, 而 `run_batch` 在之前, 导致 `total_prefill_busy_us` 含义不一致。作者在后续 `commit` 中已调整顺序至输入物化之前。
- 链式发射中是否需要重新 `stamp`: LarrySimingDeng 提问链式发射中是否不需要更新 `forward_iter/launch_ts`, 因为 `process_batch_result` 使用的是 `batch_copy`。作者解释保留 `forward_iter` 的目的是为了维持 SWA 维护的 `cadence` (`maybe_evict_swa` 依赖 `forward_iter`), 因此保留 `forward_iter` 赋值, 删除 `launch_ts` 赋值。
- 优雅退出时 `drain` 异步工作: LarrySimingDeng 提出退出时可能存在尚未 `finalize` 的 `mx.async_eval` 作业, 建议添加 `mx.synchronize()`。作者采纳, 在 `graceful exit` 路径中加入同步调用。
- `launch_ts` 放置顺序及其对性能指标的影响 (`correctness`): 作者在后续 `commit` 中将 `_prepare_mlx_launch` 调用提前至 `resolve_forward_inputs` 之前, 使顺序与 `run_batch` 一致。
- 链式发射中 `forward_iter/launch_ts` 更新的必要性 (`design`): 作者同意保留 `forward_iter` 以维持 SWA 维护 `cadence` (`maybe_evict_swa` 依赖 `forward_iter`), 删除 `launch_ts` 赋值以避免重复。
- 优雅退出时未同步异步 Metal 工作 (`correctness`): 作者在 `graceful exit` 路径添加 `mx.synchronize()` 并注释说明理由。

风险与影响

- 风险:

- 性能指标精度: 调整 `launch_ts` 记录时间点后, `total_prefill_busy_us` 等指标的含义与标准调度器完全一致, 消除了之前可能存在的偏差, 但若用户依赖旧有的 MLX 特有指标, 可能需要重新校准。
- Graceful exit 延迟: 添加 `mx.synchronize()` 可能增加 shutdown 等待时间, 但这是释放 GPU 资源的必要步骤, 且仅发生在退出时, 不影响在线服务。
- SWA 维护频次变化: 之前因 `forward_iter` 为 `None`, SWA eviction 每步都触发 (`((None or 0) % eviction_interval == 0)`), 修复后回到正常的每 N 步执行, 可能影响长序列推理的内存行为。
- 覆盖范围: 变更仅作用于 MLX 后端, 通过 unit test 验证, 但缺少端到端 integration 测试覆盖 shutdown 场景。

- 影响:

- 用户影响: MLX (Apple Silicon) 后端用户将不再遭遇首请求崩溃, 且能正常通过 `/shutdown` 或 `ShutdownReq` 停止服务, 释放资源。之前需要手动 kill 进程。性能指标更准确。
- 系统影响: 不涉及其他后端或模块。调度器记账逻辑的变更严格限定在 `SchedulerMlxOverlapMixin` 类中, 不改变基类行为。
- 团队影响: 维持了与标准调度器一致的设计模式, 降低后续维护者理解成本。需要注意 MLX overlap 循环的特殊性已在文档中注明。
- 风险标记: MLX-specific, 核心路径变更, 性能指标含义改变, Graceful exit 延迟增加, SWA 维护频次变化

关联脉络

- PR #32445 [MLX] Stamp `launch_ts/forward_iter` in the overlap loop; fix scheduler crash on first request: 该 PR 直接关闭的 Issue, 详细描述了崩溃和动机。