

PR #30553 完整报告

sgl-project/sglang

[2/N] elastic-ep: Enable EPLB after scale-up

合并时间: 2026-07-30 01:06

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30553>

执行摘要

- 一句话: 在弹性 EP 扩容后重新启用 EPLB 专家负载均衡
- 推荐动作: 建议阅读 `eplb_manager.py` 中 `_compute_expert_location_metadata` 的广播逻辑, 以及 `model_runner.py` 中 `_rearm_eplb_after_elastic_scale` 和 `_reset_eplb_after_elastic_scale_failure` 两个方法。这些实现展示了在动态拓扑中如何安全地重新激活周期性负载均衡, 是弹性 EP 功能的关键拼图。

功能与动机

在 #30164 实现的运行时弹性 EP 扩容路径中, 扩容后 EPLB 被永久禁用, 导致拓扑变化后无法恢复周期性专家重排, 影响长期负载均衡效果。本 PR 旨在扩容完成后重新启用 EPLB。

实现拆解

1. 扩容请求时禁用 EPLB: 在 `scheduler.py` 的 `handle_scale_elastic_ep` 中, 当收到扩容请求时调用 `eplb_manager.disable_rebalance()`, 防止在扩容过程中触发专家重排。
2. 扩容最终化时重新启用: 在 `model_runner.py` 的 `_initialize_elastic_ep_joiner` 和 `_finalize_scale_up` 中, 在设置 `phase=serving_expanded` 后调用 `_rearm_eplb_after_elastic_scale()`, 该方法检查记录器状态并调用 `eplb_manager.enable_rebalance()`。
3. PLB 循环适配后缩放: 在 `eplb_manager.py` 的 `rebalance()` 中增加后缩放阶段判断: 若 `has_scaled` 且 `phase` 为 `serving_expanded` 或 `failed` 时才执行重排, 否则直接返回。新增 `_compute_expert_location_metadata()` 方法, 在后缩放时由 rank 0 计算映射并广播给所有 rank, 且使用全局 rank 而非本地 `tp_rank` 进行 P2P 移动。
4. 扁平拓扑支持: `ExpertLocationMetadata.init_by_eplb` 新增 `use_flat_topology` 参数, 当后缩放时置为 `True`, 将 `nnodes` 强制设为 1, 避免多节点拓扑扭曲映射。`ExpertLocationUpdater.update` 也同步增加该参数并传递到内部。
5. 扩容失败恢复: 在 `model_runner.py` 的 `maybe_join_ep_ranks` 中, 如果超时或 cohort 不匹配导致失败, 调用 `_reset_eplb_after_elastic_scale_failure()`, 重置分布记录器并重新启用 EPLB, 使系统可在上一次已提交的世界继续运行。
6. 测试增强: 在 `test/manual/ep/test_elastic_scale.py` 中, 在 `test_scale_up_on_demand` 测试用例末尾增加 `_generate_logprob_ok("after post-scale workload")`, 验证重排后 token 生成和 logprobs 正确性。

关键文件：

- python/sglang/srt/eplb/eplb_manager.py (模块 负载均衡; 类别 source; 类型 core-logic ; 符号 enable_rebalance, _compute_expert_location_metadata, _elastic_global_rank) : 核心修改: 新增 enable_rebalance 方法; 在 rebalance 中增加后缩放阶段检查; 新增 _compute_expert_location_metadata 处理广播映射。
- python/sglang/srt/model_executor/model_runner.py (模块 模型执行器; 类别 source; 类型 data-contract; 符号 _rearm_eplb_after_elastic_scale, _reset_eplb_after_elastic_scale_failure) : 新增 _rearm_eplb_after_elastic_scale 和 _reset_eplb_after_elastic_scale_failure 两个方法, 分别处理扩容成功和失败后的 EPLB 恢复。
- python/sglang/srt/eplb/expert_location.py (模块 专家位置; 类别 source; 类型 core-logic) : init_by_eplb 新增 use_flat_topology 参数, 用于弹性后缩放时忽略多节点拓扑。
- python/sglang/srt/eplb/expert_location_updater.py (模块 专家更新; 类别 source; 类型 core-logic) : update 方法增加 use_flat_topology 参数, 传递给内部拓扑计算。
- python/sglang/srt/managers/scheduler.py (模块 调度器; 类别 source; 类型 core-logic) : handle_scale_elastic_ep 中增加在扩容待定时禁用 EPLB 的步骤。
- test/manual/ep/test_elastic_scale.py (模块 弹性测试; 类别 test; 类型 test-coverage) : 新增后缩放 logprob 验证断言, 确保重排后 token 生成和 logprobs 正确。

关键符号: EPLBManager.enable_rebalance, EPLBManager._compute_expert_location_metadata, ModelRunner._rearm_eplb_after_elastic_scale, ModelRunner._reset_eplb_after_elastic_scale_failure, ExpertLocationMetadata.init_by_eplb (added use_flat_topology), ExpertLocationUpdater.update (added use_flat_topology), Scheduler.handle_scale_elastic_ep (added disable_rebalance)

关键源码片段

python/sglang/srt/eplb/eplb_manager.py

核心修改: 新增 enable_rebalance 方法; 在 rebalance 中增加后缩放阶段检查; 新增 _compute_expert_location_metadata 处理广播映射。

```
# EPLBManager 新增 enable_rebalance 方法, 用于扩容完成后重新激活定期重排
def enable_rebalance(self):
    self._rebalance_disabled_reason = None
    self._rebalance_disabled_logged = False
    self.reset_generator() # 重新创建生成器, 确保下次迭代进入重排

# rebalance 方法头部新增后缩放阶段检查
def rebalance(self):
    if self._rebalance_disabled_reason is not None:
        ...
    return
```

```

elastic_state = ElasticEPStateManager.instance()
is_post_scale_rebalance = elastic_state is not None and elastic_state.has_scaled
# 如果 scale 仍在进行中 (pending 或未达到 serving_expanded/failed) , 跳过本次重排
if is_post_scale_rebalance and (
    elastic_state.pending_ep_size is not None
    or elastic_state.scale_phase not in ("serving_expanded", "failed")
):
    return

# 后续正常的 rebalance 逻辑 ...
expert_location_metadata = self._compute_expert_location_metadata(
    logical_count,
    broadcast_over_world=is_post_scale_rebalance, # 后缩放时要求广播
)

```

python/sclang/srt/model_executor/model_runner.py

新增 `_rearm_eplb_after_elastic_scale` 和 `_reset_eplb_after_elastic_scale_failure` 两个方法，分别处理扩容成功和失败后的 EPLB 恢复。

扩容成功后重新启用 EPLB

```

def _rearm_eplb_after_elastic_scale(self) -> None:
    if self.eplb_manager is None:
        return
    recorder = get_global_expert_distribution_recorder()
    if not recorder.recording:
        recorder.start_record() # 确保记录器正在工作
    self.eplb_manager.enable_rebalance() # 清除禁用原因，重置生成器

```

扩容失败后恢复 EPLB (重置记录器并重新启用)

```

def _reset_eplb_after_elastic_scale_failure(self) -> None:
    if self.eplb_manager is None:
        return
    # 基于当前 expert 位置重新初始化记录器，避免数据污染
    set_global_expert_distribution_recorder(
        ExpertDistributionRecorder.init_new(
            self.server_args,
            get_global_expert_location_metadata(),
            rank=self._elastic_global_rank(),
        )
    )
    self._rearm_eplb_after_elastic_scale() # 重新启用 EPLB

```

评论区精华

唯二的 review 评论是 ShangmingCai 在 `eplb_manager.py` 第 193 行提出的优化建议: "nit: maybe deduplicate with `broadcast_global_expert_location_metadata`", 建议将新加的 `_compute_expert_location_metadata` 中的广播逻辑与已有的 `broadcast_global_expert_location_metadata` 函数去重。该建议未被合并前的代码采纳，当

前实现保留了独立广播逻辑，可能因为缩放广播与初始化广播的 world 和 rank 映射存在差异。其他 reviewer 均表示 LGTM。

- 广播 expert 映射时的去重建议 (design): 作者未直接回复，当前实现保留独立广播逻辑（可能由于缩放广播与初始化广播的 world 和 rank 映射不同）。评论被标记为 'nit'，无强制修改要求。

风险与影响

- 风险：
 1. 竞态条件: `rebalance()` 中对 `elastic_state.scale_phase` 的检查存在时间窗口，如果并发缩放与重排交错，可能导致重排使用不完整的拓扑。当前通过 `pending_ep_size` 和 `phase` 双重检查降低风险，但未加锁。
 2. 广播一致性: `_compute_expert_location_metadata` 中 rank 0 计算后广播，若广播期间其他 rank 执行了其他操作，可能导致不一致。当前依赖 `scale_phase` 同步，但应确保所有 rank 在广播前处于 barrier 状态（已在 `_elastic_scale_ready_barrier` 中做了一次全局同步）。
 3. 失败恢复路径: `_reset_eplb_after_elastic_scale_failure` 会重置 `ExpertDistributionRecorder`，若此时已有部分重排进行中，可能导致记录器丢失部分数据。
 4. Mooncake 依赖性: 依赖 Mooncake commit 9843b897 (PR #2623) 修复 P2P 阻塞，若未升级至该版本，在多 rank 扩容时存在死锁风险。
 5. 扁平拓扑潜在问题: `use_flat_topology=True` 将 `nnodes` 设为 1，可能导致跨节点专家放置策略失效，但当前弹性扩容设计为单节点，暂时可接受。- 影响: 影响范围: 仅影响启用了 `--elastic-ep-size` 的弹性 EP 部署。非弹性 EP 路径完全不受影响 (EPLB 逻辑原有行为不变)。影响程度: 中。用户将自动获得扩容后的负载均衡恢复能力，无需手动干预; 扩容失败后系统能自动恢复到上次可用拓扑，提升健壮性。系统影响: 新增约 100 行核心逻辑，增加少量广播和同步开销，但仅在扩容完成后一次，不影响推理时延。
- 风险标记: 核心路径变更，分布式同步，竞态条件，依赖 Mooncake 补丁

关联脉络

- PR #30164 [1/N] elastic-ep: Add runtime EP scale-up: 本 PR 是同一弹性 EP 系列的第二部分，依赖 #30164 提供的运行时扩容基础（包括新增的 `ElasticEPStateManager` 和 `scale API`）。
- PR #2623 [PG] Fix elastic P2P after max_world_size recovery: 本 PR 的 E2E 测试依赖 Mooncake 的修复 (commit 9843b897)，否则 P2P 通信在扩容后可能死锁。