

PR #31744 完整报告

sgl-project/sglang

[Elastic EP] Fix recovery lifecycle and add manual coverage

合并时间: 2026-07-25 14:32

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/31744>

执行摘要

- 一句话: 修复 Elastic EP 恢复生命周期并添加手动 4+4 恢复测试
- 推荐动作: 建议仔细阅读此 PR, 特别是 `post_capture_elastic_ep_recover` 方法的引入和生命周期顺序的调整。新增的手动测试是理解 Elastic EP 恢复流程的良好起点。对于使用 Elastic EP 的团队, 应确保 CI 中包含类似测试。

功能与动机

A previous initialization lifecycle refactor moved recover-joiner work away from the ordering required by Elastic EP recovery. The recovery path must complete local memory-pool setup, attention-backend initialization, warmup, and CUDA graph capture before joining the recovered process groups. This PR restores that ordering and adds a manual 4+4 recovery test that exercises the full path.

实现拆解

1. 分离 recovery 与 scale-join 逻辑: 在 `model_runner.py` 的 `_initialize_elastic_ep_joiner` 方法中, 将条件从 `is_ep_joiner` 改为 `is_ep_scale_joiner`, 使 recovery joiner 跳过该路径, 不再在此处执行 `join_process_groups`。同时移除了 recovery 路径的 `get_healthy_expert_location_src_rank` 和 `ElasticEPStateManager.reset()` 调用, 避免重复执行。
2. 新增 `post_capture_elastic_ep_recover` 方法 (在 `model_runner.py`) , 负责在 CUDA 图捕获完成后执行 `join_process_groups`、广播 expert 位置元数据、初始化 `ExpertDistributionRecorder` 并重置状态。在 `scheduler.py` 的 `init_model_worker` 中, 仅在 `--elastic-ep-backend` 启用且 `ep_join_mode == "recover"` 时调用此方法, 确保恢复发生在正确的生命周期点。
3. 参数统一: 将 `load_model_utils.py` 和 `server_args.py` 中的 `is_ep_scale_joiner` 替换为 `is_ep_joiner`, 使 recovery joiner 也能通过模型加载后的 barrier 以及正确分配端口。
4. 清理恢复路径: 在 `elastic_ep.py` 的 `maybe_recover_ep_ranks` 中移除 `broadcast_pyobj` 种子广播 (经 review 确认是空操作), 并调整函数签名以接收 `model_config` 和 `moe_ep_rank`, 以便在恢复时进行 expert 位置元数据广播。
5. 添加手动 E2E 测试: 新增 `test/manual/ep/test_elastic_recover.py`, 需要 8 GPU, 启动主节点 (4 rank) 和初始 joiner (4 rank), 杀死初始 joiner 后启动 recovery joiner, 验

证生成正常。覆盖完整恢复生命周期，CUDA graph capture 保持启用。

关键文件：

- test/manual/ep/test_elastic_recover.py (模块 弹性 EP; 类别 test; 类型 test-coverage ; 符号 `_visible_device_ids`, `_server_args`, `TestElasticRecover4To4`, `setUpClass`) : 新增手动 E2E 恢复测试, 覆盖完整的 4+4 故障恢复流程, 是验证此 PR 正确性的关键测试。
- python/sglang/srt/model_executor/model_runner.py (模块 模型运行器; 类别 source; 类型 core-logic; 符号 `post_capture_elastic_ep_recover`, `_initialize_elastic_ep_joiner`) : 核心变更文件, 新增 `post_capture_elastic_ep_recover` 方法并调整 `_initialize_elastic_ep_joiner` 以分离 recovery 和 scale-join 逻辑。
- python/sglang/srt/elastic_ep/elastic_ep.py (模块 弹性 EP 库; 类别 source; 类型 dependency-wiring; 符号 `maybe_recover_ep_ranks`) : 清理恢复路径中的无效 seed 广播, 并调整函数签名以支持 expert 位置元数据广播。
- python/sglang/srt/model_executor/model_runner_components/load_model_utils.py (模块 加载工具; 类别 source; 类型 data-contract; 符号 `dist_barrier_after_load`) : 参数名统一, 确保 recovery joiner 也能通过模型加载后的 barrier。
- python/sglang/srt/managers/scheduler.py (模块 调度器; 类别 source; 类型 core-logic) : 在正确生命周期点触发恢复加入流程。
- python/sglang/srt/server_args.py (模块 参数配置; 类别 source; 类型 core-logic) : 统一参数名, 使恢复 joiner 能正确分配端口。
- python/sglang/srt/managers/tp_worker.py (模块 TP worker; 类别 source; 类型 core-logic) : 伴随性调整。

关键符号: `post_capture_elastic_ep_recover`, `maybe_recover_ep_ranks`, `dist_barrier_after_load`, `_initialize_elastic_ep_joiner`, `_visible_device_ids`, `_server_args`, `setUpClass`, `_launch`, `_generate`, `_generate_ok`

关键源码片段

test/manual/ep/test_elastic_recover.py

新增手动 E2E 恢复测试, 覆盖完整的 4+4 故障恢复流程, 是验证此 PR 正确性的关键测试。

```
@classmethod
def setUpClass(cls):
    """启动主节点和初始 joiner, 等待服务就绪。"""
    cls.base_url = f"http://127.0.0.1:{PRIMARY_PORT}"
    visible_devices = _visible_device_ids()
    # 前 4 个 GPU 启动主节点 (node_rank=0)
    cls.primary = cls._launch(
        node_rank=0, port=PRIMARY_PORT,
        visible_devices=visible_devices[:LOCAL_EP_SIZE],
        name="primary",
    )
    # 后 4 个 GPU 启动初始 joiner (node_rank=1)
    cls.initial_joiner = cls._launch(
```

```

        node_rank=1, port=JOINER_PORT,
        visible_devices=visible_devices[LOCAL_EP_SIZE:EP_SIZE],
        name="initial_joiner",
    )
    # 等待主节点 HTTP 服务就绪
    wait_for_http_ready(
        f"{cls.base_url}/health_generate",
        timeout=DEFAULT_TIMEOUT_FOR_SERVER_LAUNCH,
        process=cls.primary,
    )

    @classmethod
    def _launch(cls, *, node_rank, port, visible_devices, name, recover=False):
        """启动 SGLang server 进程。"""
        log_path = Path(f"/tmp/elastic_ep_recover_{name}_{int(time.time())}.log")
        log_file = open(log_path, "w")
        env = os.environ.copy()
        env["CUDA_VISIBLE_DEVICES"] = ",".join(visible_devices)
        cmd = _server_args(node_rank, port, recover)
        process = subprocess.Popen(cmd, env=env, stdout=log_file, stderr=log_file)
        cls.processes.append(process)
        cls.log_files.append(log_file)
        cls.log_paths[name] = log_path
        return process

```

python/sglang/srt/model_executor/model_runner.py

核心变更文件，新增 `post_capture_elastic_ep_recover` 方法并调整 `_initialize_elastic_ep_joiner` 以分离 recovery 和 scale-join 逻辑。

```

def post_capture_elastic_ep_recover(self):
    """在 CUDA graph capture 后执行恢复加入流程。"""
    # 1. 加入恢复的进程组 (Mooncake 后端会同步状态)
    join_process_groups()
    global_ep_rank = self.ps.tp_rank + self.server_args.ep_join_rank_offset
    # 2. 广播 expert 位置元数据
    broadcast_global_expert_location_metadata(
        model_config=self.model_config,
        moe_ep_rank=global_ep_rank,
        src_rank=get_healthy_expert_location_src_rank(
            invoked_in_elastic_ep_rejoin_path=True # 标记自己为 recovery rank
        ),
    )
    # 3. 初始化 expert 分布记录器
    set_global_expert_distribution_recorder(
        ExpertDistributionRecorder.init_new(
            self.server_args,
            get_global_expert_location_metadata(),
            rank=global_ep_rank,
        )
    )

```

```
)  
# 4. 重置弹性 EP 状态管理器  
ElasticEPStateManager.instance().reset()
```

评论区精华

1. zackyoray 指出恢复路径中 broadcast_pyobj 种子广播返回值被忽略，实际是空操作，且测试使用固定种子掩盖了差异。UNIDY2002 随后移除了该广播调用。
 2. ShangmingCai 要求检查 dist_barrier_after_load 是否也应切换为 is_ep_joiner 以覆盖 recovery joiner，UNIDY2002 确认并修复。
- 恢复路径中 seed broadcast 实际是空操作 (correctness): UNIDY2002 承认并移除了该 broadcast_pyobj 调用。
 - dist_barrier_after_load 是否应使用 is_ep_joiner (correctness): UNIDY2002 确认并修复，将参数名从 is_ep_scale_joiner 改为 is_ep_joiner。

风险与影响

- 风险：
 1. 恢复路径变更可能引入回归，但新增的 E2E 手动测试覆盖了 4+4 恢复场景，且 zackyoray 手动验证了 scale-up 路径正常。
 2. 参数统一为 is_ep_joiner 可能影响 scale-join 流程，但 scale-join 时 is_ep_joiner 也为真，行为一致。
 3. 移除 broadcast_pyobj 可能破坏随机种子同步，但实际 recovery 路径中种子已通过命令行参数一致传递，且该调用本就是空操作。整体风险较低。 - 影响：影响范围限于启用 Elastic EP（后端为 Mooncake）且使用恢复模式的部署。稳态推理路径无变化，scale-join 路径无变化。团队需要运行新增的手动测试验证恢复功能。对于其他配置，影响为无。 - 风险标记：依赖 Mooncake 后端，需要手动测试验证，生命周期敏感性

关联脉络

- 暂无明显关联 PR