

PR #2581 完整报告

radixark/miles

dashboard: resolve CP/PP-sharded train dumps offline and fix a partition-reader race

合并时间: 2026-08-18 08:36

原文链接: <http://prhub.com.cn/radixark/miles/pull/2581>

执行摘要

- 一句话: 修复 CP/PP 分片下 dashboard 视图错位与 `--follow` 双计数
- 推荐动作: 值得精读。设计上把 `split/assemble` 收敛到同一个偏移函数并用 `round-trip` 测试固定, 是保持并行语义一致的典范。旧 dump 的布局恢复通过“内容分组 + 宽度校验”避免了破坏性迁移, 值得借鉴。并发 `race` 修复方式简单直接 (锁住整个读 - 解析 - 追加事务), 适合作为类似场景的参考。

功能与动机

四个用户可见 dashboard bug 都是在调试一台 GB300 16 节点 GLM-5.2 训练 (TP2/CP4/PP4) 时发现的: CP > 1 时 token 视图因拼接顺序错误而崩溃或错位; PP 下 batch 视图的 per-token 列为空; `avg staleness` 因前端重算公式差一而显示 2.75 而非 1.75; `--follow` 的 `PartitionedReader._block` 因 read-modify-write 横跨两个释放 GIL 的步骤, 导致同一字节范围被重复追加, 一个 lane 渲染出 147 个 segment 而真实只有 49 个。PR body 明确要“resolve CP/PP-sharded train dumps offline and fix a partition-reader race”。

实现拆解

1. dump 元数据增强: miles/utils/train_dump_utils.py 的 `save_debug_train_data_for_rank` 新增 `cp_rank / cp_size / qkv_format` 参数并写入 `torch.save` 字典; `save_debug_train_data` 从 `get_parallel_state()` 读取当前 CP 状态传入, 测试与离线工具仍可显式传参, 保持无 `parallel state` 可用。
2. CP 逆运算: miles/backends/training_utils/cp_utils.py 的 `get_logits_and_tokens_offset_with_cp` 增加可选 `cp_rank / cp_size`, 默认仍走 `get_parallel_state()`; 新增 `assemble_log_prob_from_cp`, 用同一偏移函数将各 rank 切片写回完整 response, 缺 rank 直接断言失败。
3. reader 重构: miles/dashboard/dump_reader.py 的 `load_joined` 改为先收集所有 shard 的 handles 与 (shard, row) 位置索引, 再通过 `_cp_layout` (新 dump 用元数据, 旧 dump 用 `_recover_cp_layout_legacy` 按 `rollout_log_probs` 内容分组加宽度校验) 确定 `cp_size / layout`; `_resolve_per_token_fields` 对 `_CP_SHARDED_FIELDS` 逐字段选择持有者 (PP 只有最后 stage 有)、处理 TP 副本去重、调用 `assemble_log_prob_from_cp` 重组, 任何无法对齐的样本标记 `alignment_failed`。
4. 并发修复: miles/dashboard/store.py 的 `_PartitionedReader._block` 用 `threading.Lock` 将 `offset` 读取、文件读取、解析、缓存更新变为一个事务。

5. 前端与测试配套: charts.js / views_tokens.js 支持 gap 断线和 bands 阴影, mask 位置序列化为 null; 新增 test_cp_log_prob_assembly.py 和 test_partitions.py 并发用例; advisory.py 将 alignment_failed 呈现为 advisory。CI 上还移除了 CP 组装测试中多余的默认 register_cpu_ci 调用以通过测试守卫。

关键文件:

- miles/dashboard/dump_reader.py (模块 读取器; 类别 source; 类型 core-logic; 符号 _cp_layout, _recover_cp_layout_legacy, _cp_widths_match, _build_train_row): 核心读取逻辑: 在 load_joined 中按 shard 收集全部 handles 与位置索引, 并通过 _cp_layout / _recover_cp_layout_legacy / _resolve_per_token_fields 按 PP/CP/TP 规则重组每个 per-token 字段到完整 response 长度, 无法对齐的样本标记 alignment_failed。
- miles/backends/training_utils/cp_utils.py (模块 CP 工具; 类别 source; 类型 core-logic; 符号 assemble_log_prob_from_cp, get_logits_and_tokens_offset_with_cp): 新增 assemble_log_prob_from_cp 作为 CP 切片的精确逆函数, 并让 get_logits_and_tokens_offset_with_cp 支持显式 cp_rank/cp_size, 保持 split/assemble 两侧共用同一偏移计算。
- miles/utils/train_dump_utils.py (模块 训练转储; 类别 source; 类型 data-contract; 符号 save_debug_train_data, save_debug_train_data_for_rank): dump 时记录 cp_rank/cp_size/qkv_format, 使离线 reader 能确切知道每个 shard 的切片归属, 是后续 CP 逆运算的前提。
- miles/dashboard/store.py (模块 存储层; 类别 source; 类型 core-logic; 符号 _PartitionReader._block, _PartitionReader.init): 修复 PartitonedReader._block 的读 - 改 - 写 race, 加锁使 offset 读取、文件读取、解析和追加成为原子事务, 消除 --follow 双计数。
- miles/dashboard/static/charts.js (模块 图表; 类别 source; 类型 core-logic; 符号 drawChart): 前端图表修复折线跨越 null gap 画直线的问题, 并支持 bands 阴影提示 prompt/mask 区域, 是 token 视图可读性的关键支撑。
- tests/fast/dashboard/test_partitions.py (模块 分区测试; 类别 test; 类型 test-coverage; 符号 _counting_reader, test_concurrent_fill_does_not_duplicate_records, test_concurrent_refresh_does_not_duplicate_records): 新增两个确定性并发测试, 覆盖 follow 线程与请求处理线程在同一个陈旧 offset 竞争的场景, 验证不重复追加记录。
- tests/fast/backends/training_utils/test_cp_log_prob_assembly.py (模块 CP 测试; 类别 test; 类型 test-coverage; 符号 _split, test_split_then_assemble_is_identity_thd, test_split_then_assemble_is_identity_bshd, test_partial_group_is_rejected): 用 round-trip 测试固定 CP split/assemble 逆运算, 覆盖 thd/bshd 与缺失 rank 拒绝, 是 CP 重组正确性的重要保障。
- miles/dashboard/static/views_tokens.js (模块 Token 视图; 类别 source; 类型 core-logic; 符号 renderTokens, loadTokensPane): token 视图补充 prompt/masked bands、null 序列化处理, 并对缺失 conversation 给出提示, 避免静默丢弃向用户误导。
- miles/dashboard/advisory.py (模块 告警; 类别 source; 类型 core-logic; 符号 _rollout_advisories): 将 alignment_failed 样本转化为用户可见 advisory, 区分“未 dump”和“dump 了但无法对齐”两种场景。

- tests/fast/dashboard/test_dump_reader_views.py (模块 视图测试; 类别 test; 类型 test-coverage; 符号 test_tokens_null_the_stats_where_the_loss_is_masked) : 调整 mask=0 位置的序列化断言为 null, 防止占位零被误认为真实数值, 与 chart 的 gap/bands 逻辑呼应。
- miles/dashboard/static/views_rollout.js (模块 Rollout 视图; 类别 source; 类型 core-logic) : 调整 rollout 视图, 避免前端自行重算 staleness, 改为读取后端计算的 per-sample 值。
- miles/dashboard/serve.py (模块 服务入口; 类别 source; 类型 core-logic) : 服务入口适配 summary 缓存版本或相关 endpoint 调整, 支撑样本表新增 staleness 列。

关键符号: assemble_log_prob_from_cp, get_logits_and_tokens_offset_with_cp, slice_log_prob_with_cp, _cp_layout, _recover_cp_layout_legacy, _cp_widths_match, _build_train_row, _resolve_per_token_fields, save_debug_train_data, save_debug_train_data_for_rank, _PartitionReader._block, drawChart, renderTokens, loadTokensPane

关键源码片段

miles/dashboard/dump_reader.py

核心读取逻辑: 在 load_joined 中按 shard 收集全部 handles 与位置索引, 并通过 _cp_layout / _recover_cp_layout_legacy / _resolve_per_token_fields 按 PP/CP/TP 规则重组每个 per-token 字段到完整 response 长度, 无法对齐的样本标记 alignment_failed。

只有这些 per-token 字段按 CP 切片存放; 其余字段都是全长度

```
_CP_SHARDED_FIELDS = (
    "log_probs",
    "rollout_log_probs",
    "ref_log_probs",
    "entropy",
    "ref_entropy",
    "advantages",
    "returns",
)
```

```
def _resolve_per_token_fields(row: TrainRow, handles: list[dict], locations: list[tuple[int, int]]) -> TrainRow:
```

"""把 `row` 的每个 per-token 字段填成完整 response 长度。

统一在这里决定某个字段由哪个 shard 负责, 因此 pipeline 并行 (谁算的)、张量并行 (冗余副本) 和上下文并行 (谁持有哪段切片) 只处理一次, 而不是每个视图各自实现一套可能出错的规则。

"""

```
cp_size, layout, ok = _cp_layout(handles, locations, row.total_length, row.response_length)
row.alignment_failed = not ok
```

取首个 shard 作为主 shard, qkv_format 和 max_seq_len 用于 bshd 分块

```

primary = handles[locations[0][0]]["rollout_data"]
qkv_format = handles[locations[0][0]].get("qkv_format", "thd")
max_seq_lens = primary.get("max_seq_lens")
max_seq_len = None if max_seq_lens is None else int(max_seq_lens[locations[0][1]])

for field in _CP_SHARDED_FIELDS:
    holders = [
        (shard, row_no) for shard, row_no in locations
        if handles[shard]["rollout_data"].get(field) is not None
    ]
    if not holders:
        # pipeline 并行下只有最后一个 stage 计算它，这里视为未 dump
        setattr(row, field, None)
        continue

    chunks: dict[int, torch.Tensor] = {}
    for shard, row_no in holders:
        if shard in layout:
            # setdefault: TP 副本共享同一个 cp_rank，保持选择顺序无关
            chunks.setdefault(layout[shard], handles[shard]["rollout_data"][field][row_no])

    if cp_size == 1:
        setattr(row, field, next(iter(chunks.values()), None))
        continue
    if len(chunks) != cp_size:
        # 切片不齐说明 dump 不完整，宁可置空并标记，也不显示错位数据
        setattr(row, field, None)
        row.alignment_failed = True
        continue

    setattr(
        row,
        field,
        assemble_log_prob_from_cp(
            chunks, row.total_length, row.response_length, cp_size,
            qkv_format=qkv_format, max_seq_len=max_seq_len,
        ),
    )

# 矫正：任何字段长度不等于 response_length 都会与全长度 mask 错配，
# 因此统一置空并标记 alignment_failed，而不是展示被截断 / 错位的值
for field in _CP_SHARDED_FIELDS:
    values = getattr(row, field)
    if values is not None and len(values) != row.response_length:
        setattr(row, field, None)
        row.alignment_failed = True
return row

```

修复 `PartitonedReader._block` 的读 - 改 - 写 race，加锁使 `offset` 读取、文件读取、解析和追加成为原子事务，消除 `--follow` 双计数。

```
def _block(self, key: str, path: Path) -> Any:
    # 读文件 + 解析都会释放 GIL；不加锁时两个线程可能从同一个陈旧 offset
    # 读到相同字节并各自追加一次，导致重复记录。这里把 offset 读取、
    # 文件读取、解析和缓存更新包成一个事务。
    with self._lock:
        offset = self._offsets.get(key, 0)
        if key in self._blocks and path.stat().st_size <= offset:
            self._blocks.move_to_end(key)
            return self._blocks[key]

        with open(path, "rb") as f:
            f.seek(offset)
            chunk = f.read()
            end = chunk.rfind(b"\n")
            if end >= 0:
                new = self._parse(chunk[: end + 1], path, offset)
                pieces = [self._blocks[key], new] if key in self._blocks else [new]
                self._blocks[key] = self._concat([piece for piece in pieces if self._length(piece)])
                self._offsets[key] = offset + end + 1
            elif key not in self._blocks:
                self._blocks[key] = self._concat([])
                self._offsets[key] = offset

        self._blocks.move_to_end(key)
        while len(self._blocks) > self._max_blocks:
            evicted, _ = self._blocks.popitem(last=False)
            self._offsets.pop(evicted, None)
        return self._blocks[key]
```

评论区精华

PR 没有收到实质性的逐行 review 评论。Zhichenzzz 在最后提交后直接批准 (LGTM)，`claude[bot]` 仅自动提醒该仓库配置了手动 review。最有价值的反馈实际上来自提交历史：最后一个提交由 Zhichenzzz 完成，移除了 CP 组装测试中默认形式的 `register_cpu_ci(...)` 调用，因为 `tests/ci/test/test_ci_register.py` 断言禁止这种默认形式，该失败会卡住 `stage-a-cpu` 并导致整个 CI 报告 10 个 `skipped lane`，说明测试策略守卫会抓住隐藏的冗余配置。

- 整体批准与 CI 守卫修复 (other): PR 获批合并；CI 的 `register_cpu_ci` 调用被删除以保持测试 /CI 策略一致。
- CP 反向组装的设计对称性 (design): 采用共享偏移 helper 加 round-trip 测试，确保逆运算精确。

风险与影响

- 风险:

1. assemble_log_prob_from_cp 的逆运算精确性完全依赖 get_logits_and_tokens_offset_with_cp 的偏移语义不回退；如果未来修改 chunk 算法而未同步更新，round-trip 测试虽然会失败，但生产环境的错位告警可能更早出现。
2. 旧 dump 布局恢复采用 rollout_log_probs 内容匹配加宽度校验；若多个 rank 的切片恰好内容相同（如全零或常量），_recover_cp_layout_legacy 可能错误分组，_cp_widths_match 只能拦截宽度不匹配的误判。
3. _PartitionReader._block 加锁使所有分区读取串行化，--follow 高频轮询或大量并发请求时可能存在锁竞争，需要关注 dashboard 吞吐。
4. 前端图表改动 (bands、gap) 是纯视觉变更，没有自动视觉回归测试，回归风险依赖手动验证。
5. 新增 dump 字段改变了 train_data/*.pt 的 schema，旧 dump 通过 legacy 恢复，新 dump 若由旧版 reader 在部署回滚时读取会忽略新字段，行为仍安全。- 影响：用户：使用 CP/PP 大规模并行训练（如 GB300 16 节点 GLM-5.2）时，dashboard 的 token 视图和 batch 视图首次可正常使用，不再出现错位或空列；--follow 模式计数恢复正确。系统：train dump 文件增加 3 个字段，磁盘占用可忽略；dashboard reader 对旧 dump 有兼容回退。团队：将 CP 切片与装配的偏移计算收敛到 cp_utils 单一来源，后续并行语义变更只需改一处；同时暴露了 CI 测试策略守卫对默认 register_cpu_ci 调用的严格约束。- 风险标记：逆运算依赖偏移函数稳定性，旧 dump 布局推断有误判可能，分区读取加锁影响吞吐，前端图表改动缺视觉回归测试，新增 dump schema 需兼容旧数据

关联脉络

- PR #2589 Do not abort in-flight requests when bumping the engine weight version: 同一 rollout/weight-version 一致性链路，本 PR 的 staleness 统计正是围绕 weight_version 计算。
- PR #2544 Do not kill the run when one sample's collect_samples loses its connection: 同为 rollout/sample 数据链路上的容错与一致性修复，且都补充了针对断连 / 竞态的回归测试。