

# PR #2765 完整报告

radixark/miles

feat(metrics): log per-rollout response lengths

合并时间: 2026-08-28 05:54

原文链接: <http://prhub.com.cn/radixark/miles/pull/2765>

## 执行摘要

- 一句话: 新增 per-rollout 响应长度指标, 覆盖 compaction 场景
- 推荐动作: 值得精读。该 PR 展示如何在指标层正确处理 session compaction 的语义 (sibling 求和避免重复计数), 以及如何通过统一的 episode identity 辅助函数同时修复既有 bug 并支撑新功能; review 中 P1/P2 都是真实可复现的指标错误, 修复思路与测试覆盖值得借鉴。

## 功能与动机

Session compaction 会把一个 rollout 拆成多个训练样本, 现有 per-sample 指标无法反映原始 episode 的实际训练 token 量, 需要补充 per-rollout 视角; 同时 Multi-LoRA 下各个 adapter 的 rollout ID 独立编号, 直接聚合会产生错误的统计结果。PR body 中明确说明要记录 'per-episode response-length metrics in addition to the existing per-sample metrics', 并强调 'Shared prefixes across compacted sibling samples are counted once'。

## 实现拆解

1. 提取统一的 episode 身份解析: 在 miles/ray/rollout/metrics.py 中新增 `_get_rollout_key(sample, position)`, 统一处理 rollout\_id、index、position 三种样本身份来源, 并把 sample.adapter 纳入 key 作用域, 供 `_compute_training_sample_metrics` 与新函数共用。这一步同时修复了 `_compute_training_sample_metrics` 原先在 Multi-LoRA 下缺少 adapter 作用域、可能合并不同 adapter episode 的隐患。
2. 新增 per-rollout 长度聚合函数: 实现 `_compute_episode_response_length_metrics(samples)`。先判断是否存在 sample.adapter is not None, 有则整体返回空字典 (Multi-LoRA 跳过); 否则遍历样本, 用 `_get_rollout_key` 分组, 对每组累加 `effective_response_length` (remove\_sample=True 时计为 0) 得到可训练长度, 再累加 `sample.response_length` 得到总长度; 最后用 `compute_statistics` 输出 `episode_response_length/{mean,median,max,min}`, 并对各 rollout 的总长度求平均输出 `episode_total_response_length/mean`。
3. 接入主流程: 在 `_compute_metrics_from_samples` 中调用上述新函数, 使其结果随 rollout/ 前缀写入日志与 tracking, 与既有 `response_len/*` 指标并存。
4. 测试配套: tests/fast/ray/rollout/test\_metrics.py 新增 `TestEpisodeResponseLengthMetrics` 类, 覆盖 compaction 兄弟先求和、单样本等价性、空样本、total 长度统计、Multi-LoRA 跳过、remove\_sample 零化共 6 个场景; 合并最新

main 后 30 个测试全部通过。

5. 文档配套: examples/experimental/terminus-compaction/README.md 补充两组新指标的定义与 Multi-LoRA 下不输出的说明。

关键文件:

- miles/ray/rollout/metrics.py (模块 指标聚合; 类别 source; 类型 core-logic; 符号 `_get_rollout_key`, `_compute_episode_response_length_metrics`, `_compute_metrics_from_samples`, `_compute_training_sample_metrics`): 核心逻辑文件: 新增 `_compute_episode_response_length_metrics`, 提取并改造 `_get_rollout_key` 纳入 adapter 作用域, 并接入 `_compute_metrics_from_samples`; 同时影响 `_compute_training_sample_metrics` 的 key 生成。
- tests/fast/ray/rollout/test\_metrics.py (模块 指标测试; 类别 test; 类型 test-coverage; 符号 `TestEpisodeResponseLengthMetrics`, `test_compacted_siblings_are_summed_before_computing_statistics`, `test_single_sample_rollouts_match_sample_level_statistics`, `test_empty_samples_emit_no_episode_length_metrics`): 新增 `TestEpisodeResponseLengthMetrics` 测试类, 完整覆盖 compaction 求和、单样本等价性、空样本、total 长度、Multi-LoRA 跳过与 `remove_sample` 零化等关键语义。
- examples/experimental/terminus-compaction/README.md (模块 示例文档; 类别 docs; 类型 documentation): 补充新指标的语义定义, 并明确 Multi-LoRA 场景不输出这些指标, 帮助用户正确解读日志。

关键符号: `_get_rollout_key`, `_compute_episode_response_length_metrics`, `_compute_metrics_from_samples`, `_compute_training_sample_metrics`

## 关键源码片段

### miles/ray/rollout/metrics.py

核心逻辑文件: 新增 `_compute_episode_response_length_metrics`, 提取并改造 `_get_rollout_key` 纳入 adapter 作用域, 并接入 `_compute_metrics_from_samples`; 同时影响 `_compute_training_sample_metrics` 的 key 生成。

```
def _get_rollout_key(sample: Sample, position: int) -> tuple[AdapterRef | None, str, int | None, int]:
```

```
    # Adapter 身份用于限定 rollout ID, 因为每个 Multi-LoRA 数据源会独立编号,
    # 不同 adapter 可能复用相同的 group_index / index。
    if sample.rollout_id is not None:
        return (sample.adapter, "rollout", sample.group_index, sample.rollout_id)
    if sample.index is not None:
        return (sample.adapter, "sample", sample.group_index, sample.index)
    return (sample.adapter, "position", sample.group_index, position)
```

```
def _compute_episode_response_length_metrics(samples: list[Sample]) -> dict[str, float]:
```

```
    """按原始 rollout 聚合可训练与总响应 token 数。
```

Session compaction 会把一个 rollout 拆成多个训练样本 (sibling samples) ,

它们共享同一个 rollout ID，因此需要先按 rollout 求和再计算批次级统计量，避免把同一 episode 的片段当成多个独立 episode 重复计数。  
可训练长度只统计 loss mask 命中的 token；总长度则统计每个样本中 masked 与 unmasked 的全部响应 token。

```
"""
```

```
# Multi-LoRA 下每个 adapter 拥有独立的 RolloutDataSource，rollout ID 仅在
# 各自数据源内有效；直接聚合会错误合并多个 episode，因此在支持
# adapter 级聚合前整体跳过。
if any(sample.adapter is not None for sample in samples):
    return {}
```

```
effective_lengths_by_rollout: dict[tuple[AdapterRef | None, str, int | None, int], int] = {}
total_lengths_by_rollout: dict[tuple[AdapterRef | None, str, int | None, int], int] = {}
```

```
for position, sample in enumerate(samples):
    rollout_key = _get_rollout_key(sample, position)
    # remove_sample 的样本在 convert_samples_to_train_data() 中会被清除
    # loss mask、不参与训练，因此在可训练长度中按 0 计数，但总 footprint 保留。
    effective_length = 0 if sample.remove_sample else sample.effective_response_length
    effective_lengths_by_rollout[rollout_key] = (
        effective_lengths_by_rollout.get(rollout_key, 0) + effective_length
    )
    total_lengths_by_rollout[rollout_key] = (
        total_lengths_by_rollout.get(rollout_key, 0) + sample.response_length
    )
```

```
if not effective_lengths_by_rollout:
    return {}
```

```
log_dict = {}
log_dict |= dict_add_prefix(
    compute_statistics(list(effective_lengths_by_rollout.values())),
    "episode_response_length/",
)
log_dict["episode_total_response_length/mean"] = float(
    np.mean(list(total_lengths_by_rollout.values()))
)
return log_dict
```

## tests/fast/ray/rollout/test\_metrics.py

新增 `TestEpisodeResponseLengthMetrics` 测试类，完整覆盖 compaction 求和、单样本等价性、空样本、total 长度、Multi-LoRA 跳过与 remove\_sample 零化等关键语义。

```
class TestEpisodeResponseLengthMetrics:
    def test_compacted_siblings_are_summed_before_computing_statistics(self):
        # 同一 rollout_id=10 下有两个 sibling samples (group_index=0) ,
        # 它们应被合并为一个 episode：可训练长度为 2 + 3 = 5,
        # 而 group_index=1 的另一个 rollout_id=10 是独立 episode（长度 6）。
        samples = [
```

```

        make_sample(group_index=0, index=0, rollout_id=10, response_length=5, loss_mask=[1,
        1, 0, 0, 0]),
        make_sample(group_index=0, index=0, rollout_id=10, response_length=7, loss_mask=[1,
        1, 1, 0, 0, 0, 0]),
        make_sample(group_index=0, index=1, rollout_id=11, response_length=4, loss_mask=[1,
        1, 1, 1]),
        make_sample(group_index=1, index=2, rollout_id=10, response_length=8, loss_mask=[1,
        1, 1, 1, 1, 0, 0]),
    ]

    out = _compute_episode_response_length_metrics(samples)

    assert out == {
        "episode_response_length/mean": pytest.approx(5.0),
        "episode_response_length/median": pytest.approx(5.0),
        "episode_response_length/max": pytest.approx(6.0),
        "episode_response_length/min": pytest.approx(4.0),
        "episode_total_response_length/mean": pytest.approx(8.0),
    }

def test_removed_sample_has_zero_effective_length_but_keeps_total_length(self):
    # remove_sample=True 的样本不参与训练：episode 可训练长度计为 0，
    # 但总长度仍保留完整 footprint，避免低估上下文占用。
    sample = make_sample(
        index=0,
        rollout_id=10,
        response_length=5,
        loss_mask=[1, 1, 1, 1, 1],
        remove_sample=True,
    )

    out = _compute_episode_response_length_metrics([sample])

    assert out["episode_response_length/mean"] == pytest.approx(0.0)
    assert out["episode_total_response_length/mean"] == pytest.approx(5.0)

```

## 评论区精华

review 中 guapisolo 提出两条关键问题：

- [P1] Multi-LoRA 下 key 冲突：每个 adapter 拥有独立的 RolloutDataSource，不同 adapter 会复用相同的 group\_index/index，导致不同 episode 被错误合并。建议“Skip per-rollout length metrics for Multi-LoRA”，并注明 README。最终采纳为 `if any(sample.adapter is not None for sample in samples): return {}`。
- [P2] remove\_sample 虚报可训练长度：指标在 `convert_samples_to_train_data()` 清除 loss mask 之前记录，会导致 dashboard 上报实际不参与训练的 token。建议“effective length 计 0、total 保持不变”，最终通过 `effective_length = 0 if sample.remove_sample else sample.effective_response_length` 实现。

- claude[bot] 额外指出 `_compute_training_sample_metrics` 原本缺少 `adapter` 作用域 (pre-existing)，通过共享带 `adapter` 的 `_get_rollout_key` 一并修复，并有测试覆盖。最终 guapisolo 与 maocheng23 均 approve，claude[bot] 评论确认修复与测试到位。
- Multi-LoRA 下 rollout key 冲突与指标跳过 (correctness): 采纳建议：当任意 sample 带有 adapter 时整体跳过新指标，并在 README 中注明 Multi-LoRA 不输出这些指标。
- remove\_sample 样本的可训练长度虚报 (correctness): 采纳建议：remove\_sample 样本的 effective\_length 计 0，而 total\_length 保持不变。
- \_compute\_training\_sample\_metrics 缺少 adapter 作用域 (pre-existing) (correctness): 通过共享带 adapter 字段的 \_get\_rollout\_key 修复，并新增 test\_rollout\_ids\_are\_scoped\_by\_adapter 测试覆盖。

## 风险与影响

- 风险：
  1. 指标口径变化：episode\_response\_length/{mean,median,max,min} 是 per-rollout 聚合值，与既有 per-sample 的 response\_len/\* 语义不同；依赖旧口径的自动告警或看板可能产生误读。
  2. Multi-LoRA 可观测性缺口：新指标对 Multi-LoRA 整体跳过，训练不受影响，但该场景下暂时无法从 episode 维度观测 token 长度，需后续实现 adapter-scoped 聚合。
  3. remove\_sample 口径差异：同一被过滤样本在 episode\_response\_length 中计入 0、在 episode\_total\_response\_length 中保留完整长度，直接对比两组指标可能造成困惑，需确保文档说明清晰。
  4. 核心指标模块变更：miles/ray/rollout/metrics.py 是 rollout 可观测性的核心模块，\_get\_rollout\_key 被 \_compute\_training\_sample\_metrics 复用，影响所有 rollout 日志计算；合并时与 recent #2778 的 adapter-scoping 改动交织，需回归 Multi-LoRA 奖励指标。- 影响：对用户与工程师：日志和 dashboard 新增两组 rollout 维度指标，可更准确观察 compaction 场景下每个原始 episode 的实际训练 token 量与总响应 footprint，便于诊断训练吞吐与截断问题。对系统：纯统计逻辑、单次遍历，无运行时性能影响，日志键为新增、向后兼容。对团队：metrics.py 近期多个 PR (#2710、#2743、#2778) 持续演进，本次提取 \_get\_rollout\_key 形成统一的 episode 身份解析，为后续 adapter-scoped 聚合与更多 episode 级指标打了基础。- 风险标记：Multi-LoRA 指标缺口，指标口径变化，核心指标模块变更

## 关联脉络

- PR #2778 fix(metrics): scope episode rewards by adapter: 本 PR body 明确引用 #2778：episode rewards 保持 adapter-scoped；测试中复用 #2778 的 adapter-scoping 测试，且共享同一事件身份解析逻辑。
- PR #2741 Add Terminus 2 compaction training example: 本 PR 修改了该示例的 README.md，补充新指标的文档说明，属于同一 compaction 功能线。
- PR #2710 Log compaction-aware rollout metrics: 同文件 metrics.py 中 compaction 相关指标的早期演进，本次是 per-rollout 长度指标的延续。

- PR #2743 Skip non-numeric rewards in the episode average: 同样修改 `miles/ray/rollout/metrics.py`, 体现该模块指标健壮性的一系列修复。