

PR #2028 完整报告

radixark/miles

session: collect speculative-decoding counters

合并时间: 2026-07-31 14:45

原文链接: <http://prhub.com.cn/radixark/miles/pull/2028>

执行摘要

- 一句话: 补齐 session 路径 spec 计数器采集
- 推荐动作: 值得快速精读 (约 10-15 分钟)。这是一个教科书式的“双路径重复实现导致指标失真”案例: PR body 对根因、实测数据、修复后效果和数据可用性边界的分析非常扎实, 尤其“修完 spec_accept_length 但 spec_accept_rate 仍为 0, 因为字段缺失而非 bug”的区分, 展示了严谨的排查方法论。后续建议以 # TODO unify with Sample.update_from_meta_info 为线索, 推动 session 与直接 rollout 路径的元数据采集逻辑合并, 从根本上消除此类分叉。

功能与动机

PR body 明确指出: rollout/spec_accept_rate 和 rollout/spec_accept_length 在 agentic (session/TITO) rollouts 中恒为 0.0, 即使 EAGLE 在运行且引擎记录了真实 accept length。根因是 session 路径在 _compute_sample_from_openai_record 中重新派生元数据 (上方留有 # TODO unify with Sample.update_from_meta_info), 但只拷贝了 prefix_cache_info 和 weight_versions, spec_info 保持零值, 最终被 metrics.py 平均成 0。实测数据: 16 节点 GLM-5.2 运行中 64 个 dumped samples 全部 spec_info = {0, 0, 0, 0}, 而引擎日志显示 accept len: 1.77。

实现拆解

1. 定位根因

对比直接 rollout 路径的 Sample.update_from_meta_info 与 session 路径的 _compute_sample_from_openai_record, 发现后者只调用 sample.prefix_cache_info.add(...) 与 weight_versions.append(...), 遗漏 sample.spec_info.add(...), 导致 spec_info 恒为零值被 metrics.py 平均。

2. 修复核心逻辑

在 miles/rollout/session/samples/merge.py 的 _compute_sample_from_openai_record 中, 于 prefix_cache_info.add 之前新增条件采集: 当 args.sglang_speculative_algorithm 为真时调用 sample.spec_info.add(choice.get("meta_info", {})), 与直接 rollout 路径行为对齐。改动仅 +2 行, 属于控制流调整。

3. 测试配套

tests/fast/rollout/session/test_samples.py 顶部的两个 SimpleNamespace fixture (_ARGS 与 _ARGS_RECORDING) 补上 sglang_speculative_algorithm=None。这是必需改动而非装饰：新代码直接读取该属性而非 getattr 兜底，缺属性会导致该文件每个用例抛 AttributeError。

4. 验证

本地运行 tests/fast/rollout/session 与 tests/fast/rollout/session/test_lifecycle_metadata.py 共 45 个用例全部通过；16 节点 GLM-5.2 实测 spec_accept_length 从恒 0.0 恢复到 1.86-1.88，且 spec_verify_ct (362549) 与 completion_token_num (682896) 均能正常获取。

关键文件：

- miles/rollout/session/samples/merge.py (模块 会话采样；类别 source；类型 core-logic；符号 _compute_sample_from_openai_record, Sample.spec_info.add)：修复核心：在 _compute_sample_from_openai_record 中补充 spec_info 采集，使 session 路径与直接 rollout 路径的 Sample.update_from_meta_info 行为对齐，直接决定指标正确性。
- tests/fast/rollout/session/test_samples.py (模块 测试用例；类别 test；类型 test-coverage；符号 _ARGS, _ARGS_RECORDING)：两个 SimpleNamespace fixture 补 sglang_speculative_algorithm=None，防止新属性直读导致整文件用例 AttributeError，是修复的必需测试配套。

关键符号：_compute_sample_from_openai_record

关键源码片段

miles/rollout/session/samples/merge.py

修复核心：在 _compute_sample_from_openai_record 中补充 spec_info 采集，使 session 路径与直接 rollout 路径的 Sample.update_from_meta_info 行为对齐，直接决定指标正确性。

```
# 函数位于 miles/rollout/session/samples/merge.py，是 session (TITO) 路径构造 Sample 的收尾逻辑。
```

```
# 注意：这段代码与直接 rollout 路径的 `Sample.update_from_meta_info` 高度重复
```

```
# (函数上方留有 `# TODO unify with Sample.update_from_meta_info` 注释)，
```

```
# 此前只复制了 `prefix_cache_info` 与 `weight_versions`，漏掉 `spec_info`，
```

```
# 导致 agentic rollout 的 `rollout/spec_accept_length` 恒为 0.0。
```

```
match choice["finish_reason"]:
```

```
    case "stop" | "tool_calls":
```

```
        sample.status = Sample.Status.COMPLETED
```

```
    case "length":
```

```
        sample.status = Sample.Status.TRUNCATED
```

```
    case "abort":
```

```
        sample.status = Sample.Status.ABORTED
```

```
# 修复点：与 `Sample.update_from_meta_info` 对齐，
```

```
# 仅在启用 speculative 算法（如 EAGLE）时采集计数。
```

```
# `meta_info` 可能缺失，用 `get` 兜底；
```

```
# 若不采集, `spec_info` 保持零值, 被 `metrics.py` 平均后输出 0.0。
if args.sglang_speculative_algorithm:
    sample.spec_info.add(choice.get("meta_info", {}))
sample.prefix_cache_info.add(choice.get("meta_info", {}))
if "weight_version" in choice["meta_info"]:
    sample.weight_versions.append(choice["meta_info"]["weight_version"])

return sample
```

tests/fast/rollout/session/test_samples.py

两个 `SimpleNamespace` fixture 补 `sglang_speculative_algorithm=None`, 防止新属性直读导致整文件用例 `AttributeError`, 是修复的必需测试配套。

```
# tests/fast/rollout/session/test_samples.py 顶部的全局 fixture。
# 修复后的生产代码从 `args` 直接读取 `sglang_speculative_algorithm` 属性
# (而非 `getattr` 兜底), 因此这两个 fixture 必须同步补上该属性,
# 否则本文件所有用例都会在构造样本时抛出 `AttributeError`。

_ARGS = SimpleNamespace(
    save_debug_trajectory_data=None,
    sglang_speculative_algorithm=None, # 新增: 默认关闭 speculative 计数采集
)

_ARGS_RECORDING = SimpleNamespace(
    save_debug_trajectory_data="/unused/{rollout_id}.jsonl",
    sglang_speculative_algorithm=None, # 新增: 与 `_ARGS` 保持一致
)
```

评论区精华

review 本身没有实质讨论, guapisolo 直接批准 (“LGTM.”)。真正有价值的分析在 PR body 中:

- 作者明确区分“bug”与“数据不可用”两个层面: `spec_accept_length = completion_token_num / spec_verify_ct` 在修复后可正常计算; 而 `spec_accept_rate` 依赖 `spec_accept_token_num` 与 `spec_draft_token_num`, 当前 `sglang` 版本的 `meta_info` 不提供这两个字段, 因此修复后仍为 0.0, 属 engine 侧缺失, 需要上游改动。
- 实测前后对照: 修复前 64 个样本全部 `spec_info = {0, 0, 0, 0}`, 引擎日志 `accept len: 1.77`; 修复后指标为 1.86-1.88, 确认根因判断正确。
- 另有一条 `gemini-code-assist` 机器人的公告评论 (`Gemini Code Assist` 已停服), 与本次变更无关。
- `spec_accept_rate` 修复后仍为 0.0 是否仍是 bug (question): 认定为数据可用性限制而非 bug; 补齐这两个字段需要 `sglang engine` 侧改动, 超出本 PR 范围。
- 测试 fixture 补属性是必需改动而非装饰 (testing): 通过测试配套保证修复后的代码在测试环境中不回归, 45 个用例全部通过。

风险与影响

- 风险：
 - 属性直读风险：新代码用 `args.sglang_speculative_algorithm` 直接取属性（替代 `getattr` 模式），任何未配置该属性的调用方会在构造样本时抛 `AttributeError`；PR 已同步更新测试 fixture，但需确认生产环境所有调用 `compute_samples_from_openai_records` 的入口都设置了该属性。
 - 指标口径变化：`spec_accept_length` 从恒 0 变为真实值，会改变依赖它的下游报表与历史基线对比，纵向比较旧数据时需注意口径不一致。
 - 残留误导风险：`spec_accept_rate` 继续为 0.0，容易被误读为“EAGLE 无收益”，建议在指标面板或文档标注其为数据不可用（当前 `sglang` 版本缺字段）而非真实为零。
 - 代码重复风险：本修复延续了 `# TODO unify with Sample.update_from_meta_info` 指出的双路径重复实现，未来两条路径再次分叉仍可能重演此类 bug，属于未根治的隐患。
- 影响：
 - 影响功能：`agentic/session (TITO) rollouts` 的 `speculative-decoding` 指标统计，`rollout/spec_accept_length` 由错误的恒 0 变为真实值，对模型评估与 EAGLE 收益分析有直接改善。
 - 影响范围：改动仅 2 个文件、净增 6 行，属于低风险小改动；但影响所有 `session` 路径采样与指标上报。
 - 对团队：为 `spec_accept_rate` 的上报差距（engine 侧缺字段）留下明确的后续工作项，并暴露 `session` 与直接 `rollout` 两条路径需要统一实现的技术债。
 - 风险标记：属性直读新增 `AttributeError` 风险，指标口径变化影响历史对比，`spec_accept_rate` 仍为 0 易误读，双路径重复实现未根治

关联脉络

- 暂无明显关联 PR