

PR #26252 完整报告

sgl-project/sglang

[observability] add Ray metric backend wrappers

合并时间: 2026-06-18 10:41

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/26252>

执行摘要

- 一句话: 为 SGLang 指标新增 Ray 后端包装器, 支持集成到 Ray 监控系统。
- 推荐动作: 值得精读, 尤其是包装器设计 (复制 + 标签绑定、边界过滤、名称净化) 和测试策略 (fake 模块注入实现 CPU 环境测试)。对于计划将 SGLang 嵌入 Ray Serve 的用户, 本 PR 提供了零配置接入路径。

功能与动机

下游平台希望将 SGLang 指标通过 Ray 的 `ray.util.metrics` 代理展示, 避免单独部署 `prometheus_client`; 此前只能 fork 或自行封装。本 PR 应此需求, 提供官方 Ray 后端。

实现拆解

1. 在 `ray_wrappers.py` 中实现四个包装器类 (`RayCounterWrapper`、`RayGaugeWrapper`、`RayHistogramWrapper`、`RaySummaryWrapper`), 每个继承自基类 `RayPrometheusMetric`, 将 `prometheus_client` 的 `inc/set/observe` 调用转换为 `ray.util.metrics` 对应操作, 并自动注入 `ReplicaId` 标签以区分 Ray Serve 副本。
2. 创建五个收集器子类 (如 `RaySchedulerMetricsCollector`), 继承自 `MetricsCollector` 模块的对应父类, 仅覆盖父类使用的 `_xxx_cls` 类属性, 实现类级别 DI。PR#24610 的 `_StatLoggerDIMixin` 自动处理其余属性默认值, 无需修改仪表点。
3. 处理 Ray 平台差异: `RaySummaryWrapper` 因 Ray 无 `Summary` 原语, 降级为 `Histogram` 并用保守默认边界; 实现 `_coerce_positive_boundaries` 过滤非正值边界 (如 `queue_time_seconds` 的 0.0 下界); 实现 `_get_sanitized_opentelemetry_name` 将冒号等标点替换为下划线, 符合 `OpenTelemetry` 命名规范。
4. 新增测试基础设施 `fake_ray.py`, 通过 `make_fake_ray_modules` 创建伪造的 `ray.util.metrics` 和 `ray.serve` 模块, 注入 `sys.modules`, 使单元测试无需安装 Ray 即可运行。该 fake 与 DI 单元测试共享。
5. 调整现有测试: 在 `test_metrics.py` 中新增基于真实 `Engine + FileRecordingMetric` 的跨进程集成测试, 验证 DI 发射流经 Ray 包装器; 精简 `test_stat_loggers_di.py` 为纯 CPU 单元测试, 仅验证类属性默认值和角色解析逻辑。

关键文件:

- `python/sglang/srt/observability/ray_wrappers.py` (模块 可观测性; 类别 `source`; 类型 `dependency-wiring`; 符号 `_get_replica_id`, `RayPrometheusMetric`, `init`, `_get_tag_keys`)

: 核心实现: 定义 RayPrometheusMetric 基类、四个包装器、五个收集器子类, 以及工具函数 (边界过滤、名称净化)。所有 Ray 指标集成逻辑集中于此文件。

- test/registered/unit/observability/test_ray_wrappers.py (模块 测试; 类别 test; 类型 test-coverage; 符号 TestRayWrapperBase, setUp, tearDown, TestNameSanitization) : 单元测试: 覆盖包装器的所有操作 (inc/set/observe)、标签绑定、名称净化、边界过滤、DI 类的属性覆盖, 以及无 Ray 环境导入。
- python/sglang/test/observability/fake_ray.py (模块 测试辅助; 类别 test; 类型 test-coverage; 符号 FakeRayMetric, make_fake_ray_modules, FakeRayServeException, _ReplicaCtx) : 测试基础设施: 提供 FakeRayMetric 和 make_fake_ray_modules, 使单元测试和 DI 集成测试无需安装 Ray 即可运行。
- test/registered/observability/test_metrics.py (模块 测试; 类别 test; 类型 test-coverage; 符号 _FileRecordingMetric, _FileRecordingMetricBound, _record, _RecordingSchedulerCollector) : 集成测试: 新增基于 Engine 的 DI 验证, 使用 FileRecordingMetric 记录指标发射, 跨进程验证 Ray 包装器正确接入。
- test/registered/unit/observability/test_stat_loggers_di.py (模块 测试; 类别 test; 类型 test-coverage; 符号 TestCollectorClassAttrs, TestResolveCollectorClass, TestRoleConstants) : DI 单元测试: 验证类属性默认值、resolve_collector_class 逻辑、角色常量映射。重构后精简为纯 CPU 测试。

关键符号: _get_replica_id, RayPrometheusMetric.init, RayPrometheusMetric._get_tag_keys, RayPrometheusMetric._build_tags, RayPrometheusMetric.labels, RayPrometheusMetric._coerce_positive_boundaries, RayPrometheusMetric._get_sanitized_opentelemetry_name, RayCounterWrapper.inc, RayGaugeWrapper.set, RayHistogramWrapper.observe, RaySummaryWrapper.observe, FakeRayMetric.init, make_fake_ray_modules, FileRecordingMetric.labels, _FileRecordingMetricBound.inc, _RecordingSchedulerCollector.init

关键源码片段

python/sglang/srt/observability/ray_wrappers.py

核心实现: 定义 RayPrometheusMetric 基类、四个包装器、五个收集器子类, 以及工具函数 (边界过滤、名称净化)。所有 Ray 指标集成逻辑集中于此文件。

```
def _get_replica_id() -> Optional[str]:
    """Return the current Ray Serve replica ID, or None outside Serve."""
    if ray_serve is None:
        return None
    try:
        # 注意: ray_serve.get_replica_context().replica_id 已经是字符串, 无需 .unique_id
        return ray_serve.get_replica_context().replica_id
    except ray_serve.exceptions.RayServeException:
        return None

class RayPrometheusMetric:
    """Base wrapper exposing prometheus_client API on Ray metrics."""
```

```

_is_labeled: bool = False

def __init__(self) -> None:
    if ray_metrics is None:
        raise ImportError("RayPrometheusMetric requires Ray to be installed.")
    self.metric: Optional[Metric] = None
    # 初始化时注入 ReplicaId 标签
    self._tags: dict = {"ReplicaId": _get_replica_id() or ""}

    @staticmethod
    def _get_tag_keys(labelnames: Optional[List[str]]) -> tuple:
        """将用户标签键列表末尾追加 ReplicaId, 返回完整元组。"""
        labels = list(labelnames) if labelnames else []
        labels.append("ReplicaId")
        return tuple(labels)

    def _build_tags(self, *labels: str, **labelskwargs: str) -> dict:
        """构建标签字典: 位置参数按顺序填充键, 关键字参数直接合并, ReplicaId 始终由内部设置。"""
        if labels:
            # 位置参数个数等于标签键数减 1 (ReplicaId 自动填充)
            expected = len(self.metric.tag_keys) - 1 # 注意: Ray 属性名为 tag_keys
            if len(labels) != expected:
                raise ValueError(
                    f"Number of labels must match the number of tag keys. "
                    f"Expected {expected}, got {len(labels)}"
                )
            labelskwargs.update(zip(self.metric.tag_keys, labels))
        # 每次调用重新获取 ReplicaId, 保证标签最新
        labelskwargs["ReplicaId"] = _get_replica_id() or ""
        return {k: v if isinstance(v, str) else str(v) for k, v in labelskwargs.items()}

    def labels(self, *labels: str, **labelskwargs: str) -> RayPrometheusMetric:
        """返回带绑定标签的包装器副本, 禁止二次调用 labels()。"""
        if self._is_labeled:
            raise ValueError("labels() cannot be called on an already-labeled metric.")
        clone = copy.copy(self)
        clone._tags = self._build_tags(*labels, **labelskwargs)
        clone._is_labeled = True
        return clone

```

python/sglang/test/observability/fake_ray.py

测试基础设施: 提供 FakeRayMetric 和 make_fake_ray_modules, 使单元测试和 DI 集成测试无需安装 Ray 即可运行。

```

class FakeRayMetric:
    """Stand-in for ray.util.metrics.{Counter, Gauge, Histogram}.

    记录每次 inc / set / observe 调用及其标签, 方便测试断言。
    """

```

```

def __init__(self, name="", description="", tag_keys=(), boundaries=None):
    self.name = name
    self.description = description
    self.tag_keys = tuple(tag_keys) # 使用 tag_keys 匹配 Ray API
    self.boundaries = list(boundaries) if boundaries is not None else None
    self.calls = [] # 列表, 元素为 (op, value, tags)

def inc(self, value, tags=None):
    self.calls.append(("inc", value, dict(tags or {})))

def set(self, value, tags=None):
    self.calls.append(("set", value, dict(tags or {})))

def observe(self, value, tags=None):
    self.calls.append(("observe", value, dict(tags or {})))

def make_fake_ray_modules(replica_id: str = "test-replica") -> dict:
    """创建伪造的 ray 模块, 注入 sys.modules, 使得测试代码可以透明使用。"""
    # 创建 ray.util.metrics 模块并将三个 metric 类型设置为 FakeRayMetric
    ray_util_metrics = types.ModuleType("ray.util.metrics")
    ray_util_metrics.Counter = FakeRayMetric
    ray_util_metrics.Gauge = FakeRayMetric
    ray_util_metrics.Histogram = FakeRayMetric
    ray_util_metrics.Metric = FakeRayMetric

    # 模拟 ray.serve 上下文
    ray_serve = types.ModuleType("ray.serve")
    ray_serve_exc = types.ModuleType("ray.serve.exceptions")
    ray_serve_exc.RayServeException = FakeRayServeException
    ray_serve.exceptions = ray_serve_exc

    class _ReplicaCtx:
        # 真实 Ray 中 replica_id 是字符串; 此处保持与实现一致
        replica_id = replica_id

    ray_serve.get_replica_context = lambda: _ReplicaCtx()
    return {
        "ray": ...,
        "ray.util": ...,
        "ray.util.metrics": ray_util_metrics,
        "ray.serve": ray_serve,
        "ray.serve.exceptions": ray_serve_exc,
    }

```

评论区精华

Review 中 Gemini Code Assist 指出两个高优先级 bug: `_get_replica_id()` 中 `replica_id` 已是字符串不应使用 `.unique_id`; Ray Metric 类属性是 `tag_keys` 而非 `_tag_keys`。提交者均已修

正。审核者 sufeng-buaa 建议将 Engine 级 DI 测试整合到 `test_metrics.py` 以利用 `FakeRayMetric` 进行完整发射验证，作者采纳并重构了测试分层。

- Ray `replica_id` 属性访问错误 (correctness): 作者已修复，移除 `.unique_id` 访问。
- `tag_keys` 属性名错误（下划线前缀） (correctness): 作者已修复所有引用和测试 `fake` 中的属性名。
- 建议重构 Engine 级 DI 测试到 `test_metrics.py` (testing): 作者执行了迁移，在 `test_metrics.py` 中添加了 `_FileRecordingMetric` 和 `_RecordingSchedulerCollector`，通过跨进程文件标记验证发射值。

风险与影响

- 风险：风险较低：Ray 为可选依赖，模块在无 Ray 环境可导入但构造时抛出清晰 `ImportError`；Histogram 边界过滤可能略微改变统计特性（影响极低）；`ReplicaId` 标签在非 `Serve` 环境中为空字符串；默认行为不变，已有 `prometheus_client` 后端不受影响。测试覆盖 31 个单元测试和跨进程集成测试，已覆盖边界值和错误路径。
- 影响：对用户：启用 Ray 指标集成只需在 `ServerArgs.stat_loggers` 中映射对应收集器类。对团队：需维护与 vLLM 对齐的包装器代码，但核心逻辑封装在单一文件中。对系统：无运行时性能开销，仅增加可选导入分支。测试保障了主要功能和回归防止。
- 风险标记：可选依赖 Ray，Histogram 边界过滤可能改变分布，包装器与 `prometheus_client` 后端并行，`ReplicaId` 标签非 `Serve` 环境为空

关联脉络

- PR #24610 [observability] add class-level DI on MetricsCollectors and `ServerArgs.stat_loggers` role-to-subclass map: 本 PR 依赖 PR#24610 的 `_StatLoggerDIMixin` 和 `stat_loggers` 映射机制，提供具体的 Ray 后端实现。