

PR #35669 完整报告

vllm-project/vllm

Feature/offloading manager stats

合并时间: 2026-06-10 20:44

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/35669>

执行摘要

- 一句话: 为 KV offload 管理器添加标准化 Telemetry 接口
- 推荐动作: 该 PR 值得深度阅读, 特别是对设计可扩展监控系统的开发者。关键决策在于自描述扁平统计载荷的设计和 deprecation 迁移策略。建议结合 RFC (#44008) 形成的指标重设计思路来理解整体演进方向。

功能与动机

PR body 明确指出需要为 OffloadingManager 接口标准化统计上报方式, 以支持 block-reuse 频率追踪等可观测性需求。原本的 OffloadingConnectorStats 只硬编码了 transfer_type→ops_list 的结构, 无法灵活扩展新的标量统计项; 而当前设计需要新增一个通用的、可让 OffloadingManager 自定义指标的上报通道。

实现拆解

实现步骤:

1. 在 vllm/v1/kv_offload/base.py 中新增 OffloadingMetricMetadata 及其子类 (Counter/Gauge/Histogram), 并在 OffloadingManager 抽象类中增加 get_stats() 默认返回 None, 同时增加 OffloadingSpec 类的 build_metric_definitions 类方法。
2. 在 vllm/distributed/kv_transfer/kv_connector/v1/offloading/common.py 中新增 DirectionalTransferStats 和 TransferStats 两个 @dataclass, 分别记录 load/store 方向的字节、耗时和 size 列表, 支持 aggregate 和 is_empty, 并将 transfer_stats 字段插入 OffloadingWorkerMetadata 中, 使得工人端的传输统计能够随元数据上报至调度器。
3. 在 vllm/distributed/kv_transfer/kv_connector/v1/offloading/metrics.py 中进行大规模重构:
 - 定义 _TransferMetricName 常量 (如 load_bytes、load_time 等) 作为扁平指标名称。
 - 定义 _MetricType 和 _StatsKey 以支持自描述的序列化格式, OffloadingConnectorStats.data 现在由 {types: {name: type}, data: {name: value}} 结构构成。
 - 添加 get_connector_metric_definitions() 返回 connector 固有的 6 个指标 (load/store 的 bytes、time、size), 以及遗留的 3 个 deprecated 指标 (vllm:kv_offload_total_bytes 等) 用于向后兼容迁移。

- `OffloadPromMetrics.observe()` 新实现改为按 metric name 从 `self._offloading_manager_metric_metadata` 中查找类型，然后调用对应的 `inc/observe/set`。
4. 在 `vllm/distributed/kv_transfer/kv_connector/v1/offloading/scheduler.py` 中：
- `OffloadingConnectorScheduler` 新增 `_connector_stats` 字段，`update_connector_output()` 中将工人上报的 `TransferStats` 拆解为 flat connector stats 并聚合。
 - 新增 `get_stats()` 方法，合并来自 `self._connector_stats` 和 `self.manager.get_stats()` 的结果。
5. `FilteredOffloadingManager`（在 `cpu/manager.py` 中作为内部装饰器）的 `get_stats()` 返回 `stores_skipped` 计数，其定义在 `CPUOffloadingSpec.build_metric_definitions()` 中注册。
6. 测试配套：`tests/v1/kv_connector/unit/offloading_connector/test_metrics.py` 彻底重写，添加了对 `OffloadingConnectorStats` 各种聚合语义、自描述载荷、`deprecated` 兼容过渡等的单元测试；`tests/v1/kv_connector/unit/test_offloading_connector.py` 新增 `test_cpu_offloading_metrics` 端到端测试，使用 LLM 实例实际运行并检查 Prometheus 注册表中的新指标；`tests/v1/kv_offload/cpu/test_manager.py` 增加 `stores_skipped` 计数器测试。

关键文件：

- `vllm/distributed/kv_transfer/kv_connector/v1/offloading/metrics.py`（模块 指标层；类别 source；类型 core-logic；符号 `_TransferMetricName`, `_TransferType`, `get_connector_metric_definitions`, `_MetricType`）：核心指标文件，新增了扁平指标名称定义、自描述统计载荷结构、`deprecated` 指标兼容块，以及 `OffloadPromMetrics` 对动态指标定义的支持。占总变更行数约 65%。
- `vllm/v1/kv_offload/base.py`（模块 抽象层；类别 source；类型 core-logic；符号 `OffloadingMetricMetadata`, `OffloadingCounterMetadata`, `OffloadingGaugeMetadata`, `OffloadingHistogramMetadata`）：抽象基类新增指标元数据类层次结构、`get_stats` 方法、`OffloadingSpec` 的 `build_metric_definitions` 类方法，为所有 `OffloadingManager` 实现提供了标准化扩展点。
- `vllm/distributed/kv_transfer/kv_connector/v1/offloading/common.py`（模块 工人统计；类别 source；类型 core-logic；符号 `DirectionalTransferStats`, `TransferStats`, `OffloadingWorkerMetadata.transfer_stats`）：新增 `DirectionalTransferStats` 和 `TransferStats` 两个 `dataclass`，用于在工人端收集按方向分类的传输统计信息，并嵌入 `OffloadingWorkerMetadata` 随元数据上报。
- `vllm/distributed/kv_transfer/kv_connector/v1/offloading/scheduler.py`（模块 调度层；类别 source；类型 core-logic；符号 `init`, `update_connector_output`, `get_stats`）：调度器侧集成：在 `update_connector_output` 中拆解工人上报的 `TransferStats` 为扁平 `ConnectorStats`；新增 `get_stats()` 方法合并管理器指标。
- `tests/v1/kv_connector/unit/offloading_connector/test_metrics.py`（模块 测试指标；类别 test；类型 test-coverage；符号 `_FakeMetric`, `_FakeVllmConfig`, `_metric_metadata`, `test_build_kv_connector_stats_with_none`）：全面重写的单元测试，覆盖新的

OffloadingConnectorStats 各种聚合、扁平载荷序列化、deprecated 兼容等各类场景。

- tests/v1/kv_connector/unit/test_offloading_connector.py (模块 集成测试; 类别 test; 类型 test-coverage; 符号 test_cpu_offloading_metrics, _get_counter_value, _get_histogram_count) : 新增端到端集成测试 test_cpu_offloading_metrics, 使用 LLM 实例实际运行并验证 Prometheus 注册表中出现新的扁平指标和遗留指标。

关键符号: OffloadingManager.get_stats, OffloadingSpec.build_metric_definitions, OffloadingConnectorStats.increase_counter, OffloadingConnectorStats.set_gauge, OffloadingConnectorStats.observe_histogram, OffloadingConnectorStats.aggregate, OffloadingConnectorStats.reduce, OffloadingConnectorStats.reset, DirectionalTransferStats.aggregate, DirectionalTransferStats.record, TransferStats.aggregate, OffloadingWorkerMetadata.aggregate, OffloadingConnectorScheduler.init, OffloadingConnectorScheduler.update_connector_output, OffloadingConnectorScheduler.get_stats, OffloadPromMetrics.init, OffloadPromMetrics.observe, get_connector_metric_definitions, CPUOffloadingSpec.build_metric_definitions

关键源码片段

vllm/v1/kv_offload/base.py

抽象基类新增指标元数据类层次结构、get_stats 方法、OffloadingSpec 的 build_metric_definitions 类方法, 为所有 OffloadingManager 实现提供了标准化扩展点。

```
# vllm/v1/kv_offload/base.py
```

```
@dataclass(frozen=True)
class OffloadingMetricMetadata:
    """所有指标元数据的基类: 包含说明文字。"""
    documentation: str
```

```
@dataclass(frozen=True)
class OffloadingCounterMetadata(OffloadingMetricMetadata):
    """单调递增计数的元数据。"""
    pass
```

```
@dataclass(frozen=True)
class OffloadingGaugeMetadata(OffloadingMetricMetadata):
    """可上下波动的瞬时值的元数据。"""
    pass
```

```
@dataclass(frozen=True)
class OffloadingHistogramMetadata(OffloadingMetricMetadata):
    """分布直方图的元数据, 可选 bucket 边界。"""
    buckets: tuple[float, ...] | None = None
```

```

class OffloadingManager(ABC):
    # ... 原有抽象方法 ...

    def get_stats(self) -> "OffloadingConnectorStats | None":
        """
        返回自上次调用后收集的统计信息，若未启用则返回 None。
        子类可以重写此方法来提供 Manager 特有的指标（如 stores_skipped）。
        """
        return None

    # ... shutdown 等方法 ...

class OffloadingSpec(ABC):
    @classmethod
    def build_metric_definitions(
        cls, vllm_config: "VllmConfig"
    ) -> dict[str, "OffloadingMetricMetadata"]:
        """
        返回此 Spec 所需的 Prometheus 指标定义字典。
        key 是 metric name, value 是对应的元数据对象。
        """
        return {}

    def __init__(self, vllm_config: "VllmConfig", kv_cache_config: "KVCacheConfig"):
        # ...

```

评论区精华

Review 中最核心的讨论包括：

1. 数据结构扁平化还是嵌套→ 最终采用扁平键结构（如 xfer:cpu_to_gpu_total_bytes 前缀），而不是嵌套的 transfers/gauges 两层字典。此决策由 markmc 提出，orozery 和 Srinivasoo7 采纳。
2. stores_skipped 应为 Counter 还是 Gauge→ markmc 指出这是一个单调递增计数，Prometheus 术语上应该是 Counter；最终实现中将其作为 Counter 定义。
3. Deprecation 政策→ orozery 最初倾向于直接切换新指标，但 markmc 引用了官方 deprecation policy 要求保留旧指标一个周期。最终在 _DEPRECATED_CONNECTOR_METRIC_DEFINITIONS 中保留了旧名称，通过相同数据源同时更新新旧两组 Prometheus 指标。
4. 动态指标定义→ orozery 坚持不应硬编码 Manager 指标在 connector metrics 中，应通过 OffloadingManager.get_metric_definitions() 类方法动态注册。最终设计采用了 build_metric_definitions 类方法，并由 OffloadPromMetrics 在 __init__ 时遍历所有指标定义并创建对应的 Prometheus metric 对象。
5. 序列化元数据→ orozery 发现指标元数据在 IPC 序列化时会丢失，为此将元数据作为 self.data 的一部分（_StatsKey.TYPES 字段）进行序列化，使得接收端无需预知定义即可

解析统计载荷。

- 数据结构扁平化还是嵌套 (design): 采用自描述的扁平结构, 顶层 data 包含 types 和 data 两个子键, 类型信息随载荷序列化。
- stores_skipped 应为 Counter 还是 Gauge (correctness): 最终定义为 Counter, 通过 increase_counter 方法上报。
- Deprecation 政策: 是否需要保留旧指标 (design): 保留旧名称 (vllm:kv_offload_total_bytes 等) 作为 deprecated 指标, 与新扁平指标并存, 遵循 deprecation policy。
- 动态指标定义应放在 Manager 还是 Spec 上 (design): 采用 OffloadingSpec.build_metric_definitions 类方法作为唯一入口, Manager 不直接暴露指标定义。
- 指标元数据在 IPC 序列化中丢失 (correctness): 将类型元数据嵌入 data.types 字段, 使得载荷完全自描述。

风险与影响

- 风险: 技术风险:
 - 向后兼容风险: 废弃的旧指标名称 (vllm:kv_offload_total_bytes 等) 目前同时被更新, 但如果在测试覆盖不足的情况下, 可能出现旧指标值与新指标值不一致。由于内部逻辑确保从同一份统计数据双写, 风险可控。
 - 性能影响: 每个 scheduler step 都需要序列化 / 反序列化统计载荷, 增加了 IPC 大小。但统计数据通常较小 (n 个 block 级别), 且仅当有传输操作时才产生, 所以影响可接受。
 - 聚合语义混淆: OffloadingConnectorStats 现在需要根据 _MetricType 执行不同的聚合 (counter 求和、gauge 取最新、histogram 追加列表)。如果元数据与数据不一致 (如未正确注册类型), 聚合结果可能出错。已在测试中覆盖各类场景。
- 影响: 影响范围:
 - 用户: 如果监控了旧的 vllm:kv_offload_* 指标, 将在 v0.16.x (假设) 内继续看到兼容的值; 新的扁平指标 (vllm:kv_offload_load_bytes 等) 将提供更明确的语义。新指标默认启用, 用户无需配置即可获得 stores_skipped (当 store_threshold >=2 时) 等新监控项。
 - 系统: 内部统计数据结构完全改变, 但封装在 OffloadingConnectorStats 类中, 对外部模块 (如 KVConnectorLogging) 仅暴露 reduce() 的输出, 不受影响。
 - 团队: 后续新增 OffloadingManager 实现必须覆盖 get_stats() 和 build_metric_definitions 类方法, 提供标准化接口。
 - 风险标记: 核心路径变更, IPC 序列化兼容性, deprecated 指标双写维护

关联脉络

- PR #35342 Unknown (mentioned in PR body): 本 PR body 中提到 'Since we merged PR #35342', 表明 #35342 可能增加了 offloading manager 的基础设施, 本 PR 在此基础上添加统计功能。尽管 #35342 不在提供的历史列表中, 但基于 PR 讨论, 它直接关联。