

PR #23049 完整报告

sgl-project/sglang

[Diffusion] Diffusion model support log-requests

合并时间: 2026-07-05 17:01

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/23049>

执行摘要

- 一句话: 为 Diffusion 服务添加请求日志记录功能
- 推荐动作: 值得快速浏览, 了解如何复用 srt 的日志基础设施为 diffusion 路径添加可观测性。重点关注 DiffusionRequestLogger 的设计 (采样配置白名单、级别语义) 以及钩子插入点 (scheduler_client.forward)。该 PR 为后续 diffusion 服务的运维监控奠定了基础。

功能与动机

来自 PR body 的表述: 'Diffusion model serving (image/video generation) did not support --log-requests, --log-requests-level, --log-requests-format, or --log-requests-target, so these flags were rejected at startup.' 此 PR 将这些功能引入 diffusion 运行时, 满足用户对 diffusion 服务请求级日志的需求。

实现拆解

1. 新建 DiffusionRequestLogger 类 (python/sglang/multimodal_gen/runtime/utils/request_logger.py): 该类镜像 srt 的 RequestLogger 设计, 定义了 10 个采样配置白名单字段 (_SAMPLING_CONFIG_FIELDS), 并通过 log_requests_level 控制日志详略 (0-3级)。通过 from_server_args 工厂方法从 ServerArgs 初始化, 底层使用 srt 的 create_log_targets 支持多目标 (stdout 和文件) 输出。
2. 添加 CLI 参数 (python/sglang/multimodal_gen/runtime/server_args.py): 在 ServerArgs dataclass 中新增 log_requests、log_requests_level、log_requests_format、log_requests_target 四个字段, 并在 add_cli_args 中注册对应的 argparse 参数。
3. 在 scheduler_client 中插入日志钩子 (python/sglang/multimodal_gen/runtime/scheduler_client.py): 在 SchedulerClient.initialize 中创建 DiffusionRequestLogger 实例; 在 forward() 方法开始前调用 log_received_request(batch), 在成功收到响应后调用 log_finished_request(batch, output_batch)。AsyncSchedulerClient 类也做了相同的改造, 保证同步和异步路径的一致性。
4. 编写集成测试 (python/sglang/multimodal_gen/test/server/test_request_logger.py): 使用 ServerManager 启动带有不同日志格式 (text/json) 的 diffusion 服务, 分别测试图像和视频生成场景, 验证 stdout 和文件两种目标是否正确输出 request.received 和 request.finished 事件。

5. 更新 CLI 文档 ([docs_new/docs/sglang-diffusion/api/cli.mdx](#)) : 在 Common Options 下新增 "Request logging" 小节, 说明四个参数的用法和默认值。

关键文件:

- `python/sglang/multimodal_gen/runtime/utils/request_logger.py` (模块 日志记录器; 类别 source; 类型 core-logic; 符号 `DiffusionRequestLogger`, `init`, `from_server_args`, `_request_id`) : 核心新增文件, 实现 `DiffusionRequestLogger` 类, 定义了日志级别、采样配置白名单、接收 / 完成记录的格式化逻辑。
- `python/sglang/multimodal_gen/runtime/scheduler_client.py` (模块 调度客户端; 类别 source; 类型 dependency-wiring; 符号 `SchedulerClient.initialize`, `SchedulerClient.forward`, `AsyncSchedulerClient.initialize`, `AsyncSchedulerClient.forward`) : 日志钩子插入点, 在 `SchedulerClient` 和 `AsyncSchedulerClient` 的 `forward()` 中调用日志记录, 是日志功能与调度路径结合的关键位置。
- `python/sglang/multimodal_gen/runtime/server_args.py` (模块 服务参数; 类别 source; 类型 dependency-wiring; 符号 `log_requests`, `log_requests_level`, `log_requests_format`, `log_requests_target`) : 添加了四个日志相关的 CLI 参数定义和默认值, 是用户启用日志的配置入口。
- `python/sglang/multimodal_gen/test/server/test_request_logger.py` (模块 集成测试; 类别 test; 类型 test-coverage; 符号 `_start_server`, `_cleanup_server`, `_create_client`, `_wait_for_video_completion`) : 集成测试, 验证日志输出到 `stdout` 和文件, 覆盖 `text/json` 格式和图像 / 视频模型。
- `docs_new/docs/sglang-diffusion/api/cli.mdx` (模块 文档; 类别 other; 类型 entrypoint) : 更新 CLI 文档, 新增 "Request logging" 小节, 方便用户了解日志参数。

关键符号: `DiffusionRequestLogger.init`, `DiffusionRequestLogger.from_server_args`, `DiffusionRequestLogger.log_received_request`, `DiffusionRequestLogger.log_finished_request`, `SchedulerClient.forward`, `AsyncSchedulerClient.forward`

关键源码片段

`python/sglang/multimodal_gen/runtime/utils/request_logger.py`

核心新增文件, 实现 `DiffusionRequestLogger` 类, 定义了日志级别、采样配置白名单、接收 / 完成记录的格式化逻辑。

```
# python/sglang/multimodal_gen/runtime/utils/request_logger.py (关键部分)
```

```
from typing import Any, Optional
from sglang.srt.utils.log_utils import create_log_targets
from sglang.srt.utils.request_logger import (
    _dataclass_to_string_truncated,
    _transform_data_for_logging,
)
```

```
# 记录到日志中的采样配置白名单字段 (不含 prompt)
```

```

_SAMPLING_CONFIG_FIELDS = (
    "data_type", "seed", "num_inference_steps", "guidance_scale",
    "true_cfg_scale", "width", "height", "num_frames", "fps",
    "num_outputs_per_prompt",
)

```

```

class DiffusionRequestLogger:
    def __init__(self, log_requests: bool, log_requests_level: int,
                 log_requests_format: str, log_requests_target: Optional[list]):
        self.log_requests = log_requests
        self.log_requests_level = log_requests_level
        self.log_requests_format = log_requests_format
        self.log_requests_target = log_requests_target
        # 使用 srt 的 create_log_targets 支持 stdout 和文件多目标
        self.targets = create_log_targets(
            targets=log_requests_target, name_prefix=__name__
        )
        self.log_exceeded_ms = envs.SGLANG_LOG_REQUEST_EXCEEDED_MS.get()
        # level 2 时截断 prompt 为 2 KiB, 否则不限制
        self._max_length = (
            _TRUNCATE_LENGTH if self.log_requests_level == 2 else _UNLIMITED
        )

```

@classmethod

```

def from_server_args(cls, server_args: Any) -> "DiffusionRequestLogger":
    """从 ServerArgs 构造日志记录器实例"""
    return cls(
        log_requests=server_args.log_requests,
        log_requests_level=server_args.log_requests_level,
        log_requests_format=server_args.log_requests_format,
        log_requests_target=server_args.log_requests_target,
    )

```

```

def log_received_request(self, reqs: list) -> None:
    """记录请求接收事件, 为每个 req 生成一条日志"""
    if not self.log_requests:
        return
    for req in reqs:
        rid, obj = self._batch_record([req]) # 单请求处理
        self._write_event("request.received", rid, obj)

```

```

def log_finished_request(self, reqs: list, result: Any) -> None:
    """记录请求完成事件, 包含 e2e 延迟和可能的错误"""
    if not self.log_requests:
        return
    for req in reqs:
        rid, obj = self._batch_record([req])
        result_view = self._result_view(result)
        self._write_event("request.finished", rid, obj, extra=result_view)

```

```

def _config_view(self, req: Any, *, drop_seed: bool = False) -> dict:
    """根据日志级别生成配置视图，低于 level 1 返回空"""
    sp = getattr(req, "sampling_params", None)
    if sp is None or self.log_requests_level < 1:
        return {}
    cfg = {name: getattr(sp, name, None) for name in _SAMPLING_CONFIG_FIELDS}
    if drop_seed:
        cfg.pop("seed", None)
    view: dict = {"sampling_params": cfg}
    if self.log_requests_level >= 2:
        view["prompt"] = getattr(sp, "prompt", None)
        view["negative_prompt"] = getattr(sp, "negative_prompt", None)
    return view

def _result_view(self, result: Any) -> dict:
    """从 result 提取 e2e 延迟和错误信息"""
    e2e_latency = 0.0
    metrics = getattr(result, "metrics", None) if result is not None else None
    if metrics is not None:
        e2e_latency = getattr(metrics, "total_duration_s", 0.0) or 0.0
    return {
        "meta_info": {"e2e_latency": e2e_latency},
        "error": getattr(result, "error", None) if result is not None else None,
    }

```

python/sglang/multimodal_gen/runtime/scheduler_client.py

日志钩子插入点，在 SchedulerClient 和 AsyncSchedulerClient 的 forward() 中调用日志记录，是日志功能与调度路径结合的关键位置。

python/sglang/multimodal_gen/runtime/scheduler_client.py (关键改动)

```

from sglang.multimodal_gen.runtime.utils.request_logger import (
    DiffusionRequestLogger,
)

class SchedulerClient:
    def __init__(self):
        self.context = None
        self.scheduler_socket = None
        self.server_args = None
        self.request_logger: Optional[DiffusionRequestLogger] = None # 新增 logger 属性

    def initialize(self, server_args: ServerArgs):
        self.server_args = server_args
        # 从 server_args 创建日志记录器 (默认不启用)
        self.request_logger = DiffusionRequestLogger.from_server_args(server_args)
        self.context = zmq.Context()
        self.scheduler_socket = self.context.socket(zmq.REQ)
        # ... 原有初始化代码 ...

```

```

def forward(self, batch: Any, timeout_ms: int | None = None) -> Any:
    """发送请求并等待响应，前后记录日志"""
    # 记录请求进入（scheduler 处理前）
    self.request_logger.log_received_request(batch)
    previous_timeout_ms = None
    if timeout_ms is not None:
        previous_timeout_ms = self.scheduler_socket.getsockopt(zmq.RCVTIMEO)
        self.scheduler_socket.setsockopt(zmq.RCVTIMEO, timeout_ms)
    try:
        self.scheduler_socket.send_pyobj(batch)
        output_batch = self.scheduler_socket.recv_pyobj()
        _materialize_output_batch_file_refs(output_batch)
        # 记录请求完成（收到 scheduler 响应后）
        self.request_logger.log_finished_request(batch, output_batch)
        return output_batch
    except zmq.error.Again:
        logger.error("Timeout waiting for response from scheduler.")
        raise TimeoutError("Scheduler did not respond in time.")
    finally:
        if previous_timeout_ms is not None and self.scheduler_socket is not None:
            self.scheduler_socket.setsockopt(zmq.RCVTIMEO, previous_timeout_ms)

```

评论区精华

Review 中核心讨论包括：

- 测试文件位置争议：mickqian 指出初始测试文件位于 `test/registered/utils/test_request_logger.py`，要求迁至 `python/sglang/multimodal_gen/test`。最终 PR 将测试文件置于正确位置，该争议已解决。
- `--log-requests` 默认值冗余：ping1jing2 指出 `action='store_true'` 应隐含 `default=False`，无需显式设置。但最终代码中仍保留了 `default=ServerArgs.log_requests`，该评论未导致修改。
- 日志应循环所有请求：gemini-code-assist 建议在 scheduler 的事件循环中遍历所有 `reqs` 记录完成日志，而不仅是第一条。当前实现中 `log_finished_request` 本身已对列表循环，但在 `scheduler.py` 的事件循环里仍只调用了一次。该建议未确认采纳，属于潜在的正确性关注点。
 - Diffusion 测试文件应移至正确位置 (testing)：采纳，最终测试文件移至 `python/sglang/multimodal_gen/test/server/test_request_logger.py`。
 - `--log-requests` 使用 `action='store_true'` 时默认值冗余 (style)：未修改，最终代码仍保留了 `default=ServerArgs.log_requests`。
 - `log_finished_request` 应循环所有请求 (correctness)：未明确采纳，但 PR 最终代码在 `scheduler_client.forward` 中已对 `batch` 列表循环，而 `scheduler.py` 中的调用点未修改。

风险与影响

- 风险：

1. 性能开销：当 `--log-requests-level >= 2` 时会序列化提示词（最大 2 KiB），高频请求下可能增加 IPC 和 I/O 负载。但日志默认关闭（False），用户需主动启用。
 2. 敏感信息泄露：提示词可能包含用户敏感信息，日志文件若未妥善保护可能造成泄露。默认仅记录元数据，级别 3 才输出完整提示。
 3. 调度器路径侵入：在 `SchedulerClient.forward()` 中增加日志钩子，若 logger 初始化失败可能阻塞请求路径。当前 logger 初始化不依赖外部资源，风险较低。
 4. 测试覆盖：集成测试覆盖了 text/json 格式和图像 / 视频模型，但未覆盖异步路径和错误场景（如超时、目标目录不可写）。- 影响：用户：现在可以通过指定 `--log-requests` 等参数为 diffusion 服务启用请求级日志，便于调试、监控和审计。日志格式与 LLM 路径一致，降低了运维学习成本。系统：新增的日志输出会增加磁盘 / 网络 I/O，但默认关闭，按需启用。MTP 等辅助输出不受影响。团队：维护一个独立的 `DiffusionRequestLogger`，与 SRT 的 `RequestLogger` 代码路径平行，后续功能演进需要同步更新。
- 风险标记：日志性能开销，敏感信息泄露风险，调度器路径侵入

关联脉络

- PR #30107 [diffusion] perf: add unified SP shard helpers and zero-copy tail-pad attention: 同属 diffusion 模块的基础设施改进，共享部分运行时依赖（如 `scheduler_client.py` 等）。该 PR 的日志功能与 SP 重构都是 diffusion 可观测性与性能演进的一部分。
- PR #30110 [diffusion] fix: shut down diffusion workers on serve exit: 同为 diffusion 运行时改进，涉及服务生命周期管理，与请求日志均属于服务可运维性提升。