

PR #22253 完整报告

sgl-project/sglang

[EPD] Support dynamic encoder register

合并时间: 2026-06-08 16:05

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/22253>

执行摘要

- 一句话: 为 EPD 分离添加动态编码器注册引导服务器
- 推荐动作: 值得精读。PR 展示了如何设计一个带健康检查的引导服务器, 以及与既有静态配置共存的策略。讨论中的 nEmP 支持路径对后续架构有指导意义。

功能与动机

EPD 语言服务器依赖 `--encoder-urls` 在启动时静态指定编码器地址, 无法动态添加或替换编码器。需要一个专用引导服务器使编码器自行注册, 实现灵活发现和容错。

实现拆解

1. 配置层: 在 `server_args.py` 添加 `encoder_bootstrap_port` 和 `encoder_register_urls`, 并将 `encoder_urls` 从必选改为可选。
2. 引导服务器: 在 `encode_receiver.py` 实现 `EncoderBootstrapServer` 类 (FastAPI + uvicorn), 提供 `/register_encoder_url`、`/unregister_encoder_url`、`/list_encoder_urls`、`/health` 端点, 并带健康检查循环 (连续 3 次失败自动移除)。
3. 编码器注册: 在 `encode_server.py` 实现 `_register_encoder_url_with_bootstrap` 函数, 启动守护线程以退避重试方式向每个引导服务器注册 URL (最多 30 次、间隔 5 秒)。
4. 管理器集成: 在 `tokenizer_manager.py` 的 `init_disaggregation` 中实例化 `EncoderBootstrapServer`, 并将共享 URL 列表传给 `MMReceiver`, 使接收器可直接读取同一列表。
5. 动态刷新: 在 `encode_receiver.py` 添加 `_refresh_encoder_urls_from_bootstrap`, 每次请求时 (速率限制 5 秒) 从引导服务器获取最新 URL 列表覆盖 `self.encode_urls`。
6. 修复: 在 `check_server_args` 中提前计算 `encoder_bootstrap_url` 使其被子进程继承; 在 `_send_encode_request` 中处理 `encode_urls` 为空的情况, 避免 `AttributeError`。同时将 `encoder_urls` 字段加入 `io_struct.py` 的请求对象, 确保调度器子进程中编码器分配一致性。

关键文件:

- `python/sglang/srt/disaggregation/encode_receiver.py` (模块 引导服务器; 类别 `source`; 类型 `dependency-wiring`; 符号 `EncoderBootstrapServer`, `init`, `lifespan`, `_health`): 新增 `EncoderBootstrapServer` 类 (核心组件), 以及动态刷新逻辑。

- `python/sglang/srt/disaggregation/encode_server.py` (模块 编码器启动; 类别 source; 类型 dependency-wiring; 符号 `_register_encoder_url_with_bootstrap`, `_try_register_once`, `_worker`) : 实现异步编码器注册逻辑, 后台重试注册到引导服务器。
- `python/sglang/srt/server_args.py` (模块 配置层; 类别 source; 类型 core-logic; 符号 `encoder_bootstrap_port`, `encoder_register_urls`) : 添加编码器引导服务器端口和注册 URL 列表 CLI 参数。
- `python/sglang/srt/managers/tokenizer_manager.py` (模块 管理器; 类别 source; 类型 dependency-wiring; 符号 `init_disaggregation`) : 在 `init_disaggregation` 中实例化引导服务器并传递共享 URL 列表。
- `python/sglang/srt/managers/io_struct.py` (模块 数据结构; 类别 source; 类型 core-logic; 符号 `encoder_urls`) : 在请求结构中添加 `encoder_urls` 字段, 以在子进程间传播编码器列表。
- `python/sglang/srt/envron.py` (模块 环境配置; 类别 source; 类型 core-logic; 符号 `SGLANG_ENCODER_BOOTSTRAP_HEALTH_CHECK_INTERVAL`, `SGLANG_ENCODER_BOOTSTRAP_HEALTH_CHECK_TIMEOUT`) : 添加健康检查间隔和超时环境变量。

关键符号: `EncoderBootstrapServer.register`, `EncoderBootstrapServer._health_check_loop`, `_register_encoder_url_with_bootstrap`, `_refresh_encoder_urls_from_bootstrap`

关键源码片段

`python/sglang/srt/disaggregation/encode_receiver.py`

新增 `EncoderBootstrapServer` 类 (核心组件), 以及动态刷新逻辑。

```
# python/sglang/srt/disaggregation/encode_receiver.py
# EncoderBootstrapServer 类的核心注册与健康检查逻辑
class EncoderBootstrapServer:
    """Lightweight bootstrap server for dynamic encoder discovery.

    Built on FastAPI + uvicorn, runs in a daemon thread.
    The registered URLs are stored in a list shared with MMReceiver.
    """
    def __init__(
        self,
        host: str,
        port: int,
        urls: Optional[List[str]] = None,
        health_check_interval: Optional[float] = None,
        health_check_timeout: Optional[float] = None,
    ):
        self.host = host
        self.port = port
        # _urls 与外部共享列表引用, register/unregister 直接修改此列表
        self._urls: List[str] = urls if urls is not None else []
        self._lock = threading.Lock()
```

```

self._health_check_interval = (
    health_check_interval
    if health_check_interval is not None
    else envs.SGLANG_ENCODER_BOOTSTRAP_HEALTH_CHECK_INTERVAL.get()
)
self._health_check_timeout = (
    health_check_timeout
    if health_check_timeout is not None
    else envs.SGLANG_ENCODER_BOOTSTRAP_HEALTH_CHECK_TIMEOUT.get()
)
self._consecutive_failures: Dict[str, int] = {}
self._max_consecutive_failures = 3

# FastAPI app and routes (omitted for brevity)
# ...

def register(self, url: str) -> None:
    """线程安全添加编码器 URL，避免重复。"""
    with self._lock:
        if url not in self._urls:
            self._urls.append(url)

async def _health_check_loop(self) -> None:
    """周期性健康检查，连续失败 3 次则移除 URL。"""
    while True:
        await asyncio.sleep(self._health_check_interval)
        async with ClientSession() as session:
            for url in self.list_urls():
                try:
                    async with session.get(
                        f"{url}/health",
                        timeout=ClientTimeout(self._health_check_timeout),
                    ) as resp:
                        if resp.status == 200:
                            self._consecutive_failures[url] = 0
                        else:
                            self._consecutive_failures[url] = (
                                self._consecutive_failures.get(url, 0) + 1
                            )
                except Exception:
                    self._consecutive_failures[url] = (
                        self._consecutive_failures.get(url, 0) + 1
                    )
            if self._consecutive_failures[url] >= self._max_consecutive_failures:
                logger.warning(f"Removing unhealthy encoder: {url}")
                self.unregister(url)
                self._consecutive_failures.pop(url, None)

```

[python/sglang/srt/disaggregation/encode_server.py](#)

实现异步编码器注册逻辑，后台重试注册到引导服务器。

```
# python/sglang/srt/disaggregation/encode_server.py
# 编码器启动时向引导服务器注册自身的函数
```

```
def _register_encoder_url_with_bootstrap(server_args: ServerArgs) -> None:
```

```
    """在后台线程中向所有配置的引导服务器注册本编码器 URL。
```

```
    每个引导服务器独立重试，最多 30 次，间隔 5 秒，
    避免序列化等待导致阻塞。
```

```
    """
```

```
    encoder_url = server_args.url()
    payload = {"url": encoder_url}
    bootstrap_urls = list(server_args.encoder_register_urls)
    if not bootstrap_urls:
        return
```

```
def _try_register_once(bootstrap_url: str) -> bool:
```

```
    try:
        resp = http_requests.post(
            f"{bootstrap_url}/register_encoder_url",
            json=payload,
            timeout=5.0,
        )
        if resp.status_code == 200:
            logger.info(
                "Registered encoder URL '%s' with bootstrap at %s",
                encoder_url,
                bootstrap_url,
            )
            return True
        logger.warning(
            "Bootstrap %s returned %d: %s",
            bootstrap_url,
            resp.status_code,
            resp.text,
        )
    except Exception as e:
        logger.debug("Register attempt to %s failed: %s", bootstrap_url, e)
    return False
```

```
def _worker():
```

```
    pending = list(bootstrap_urls)
    retry_count = {url: 0 for url in pending}
    while pending:
        still_pending = []
        for bootstrap_url in pending:
            if _try_register_once(bootstrap_url):
                continue
```

```

        retry_count[bootstrap_url] += 1
        if retry_count[bootstrap_url] >= 30:
            logger.error(
                "Giving up on bootstrap %s after 30 attempts."
                " Encoder discovery via this bootstrap will be incomplete.",
                bootstrap_url,
            )
            continue
        still_pending.append(bootstrap_url)
        pending = still_pending
        if pending:
            time.sleep(5.0)

    threading.Thread(
        target=_worker, daemon=True, name="encoder-bootstrap-register"
    ).start()

```

python/sclang/srt/server_args.py

添加编码器引导服务器端口和注册 URL 列表 CLI 参数。

```

# python/sclang/srt/server_args.py 新增参数定义
# (partial)
class ServerArgs:
    # ...
    encoder_bootstrap_port: int = 8997 # 语言服务器端引导服务器端口
    encoder_register_urls: List[str] = dataclasses.field(default_factory=list)
    # ...

```

评论区精华

- nEmP 支持: ShangmingCai 询问是否支持多编码器多预填充, 作者表示逐步支持, 当前仅 nE1P。
- 引导服务器位置: ShangmingCai 建议将启动从 http_server.py 移至 tokenizer_manager, 作者采纳。
- 参数冗余: ShangmingCai 认为 encoder_bootstrap_url 可由端口派生, 作者最终移除该参数。
- 健康检查配置: ZhengWG 建议通过环境变量配置, 作者添加了 SCLANG_ENCODER_BOOTSTRAP_HEALTH_CHECK_INTERVAL 和 TIMEOUT。
- 编码器 DP 兼容性: ShangmingCai 指出需在 DP 模式启动中也调用注册函数, 作者已添加。
- 自动注销: ZhengWG 提出心跳自动注销, 健康检查循环已实现但无主动心跳。
- nEmP 支持范围 (design): 作者表示逐步支持, 当前不实现 nEmP。
- 引导服务器启动位置 (design): 作者采纳并迁移。
- encoder_bootstrap_url 参数冗余 (design): 作者移除了 encoder_bootstrap_url, 仅保留端口。

- 健康检查可配置性 (design): 作者添加了 `SGLANG_ENCODER_BOOTSTRAP_HEALTH_CHECK_INTERVAL` 和 `TIMEOUT`。
- 编码器 DP 模式兼容性 (correctness): 作者在 DP 模式路径中增加了注册调用。
- 自动注销机制 (design): 健康检查循环已实现自动移除, 但未实现基于主动心跳的注销。

风险与影响

- 风险:
 - 单点故障: 引导服务器嵌在语言管理器进程中, 若该进程异常, 新编码器无法注册, 但已注册编码器仍可继续处理。
 - 最终一致性: 编码器注册不保证立即到达, 健康检查间隔 (默认 10s) 内可能发出请求到不健康编码器。
 - 静态与动态混合: 同时使用 `--encoder-urls` 和动态注册时, 列表可能包含重复, 代码已去重。
 - DP 模式覆盖: 虽已添加注册调用, 但未在测试中验证 DP 模式下的注册路径。
 - 安全暴露: 引导服务器端点无认证, 在生产环境需配置网络隔离。
 - 影响: 用户可灵活部署编码器, 无需在启动前枚举所有 URL; 编码器可以动态扩容和缩容。需要理解新的 CLI 参数。此 PR 向后兼容 (原 `--encoder-urls` 仍可用)。对现有 EPD 用户推荐升级以获得动态能力。
 - 风险标记: 引导服务器进程耦合语言管理器, 单点故障, 静态 `encoder_urls` 与动态注册混合可能产生重复, 健康检查间隙可能使用不健康编码器, 编码器 DP 模式注册路径未充分测试, 缺少主动心跳注销机制

关联脉络

- 暂无明显关联 PR