

PR #42433 完整报告

vllm-project/vllm

[EC Connector] Add EC Transfer Params

合并时间: 2026-07-12 19:35

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/42433>

执行摘要

- 一句话: 为 EC Connector 添加 `ec_transfer_params` 传输管道
- 推荐动作: 值得精读。该 PR 展示了如何在 vLLM 中新增一种跨节点传输参数 (`transfer_params`) 的完整链路, 从请求协议到调度、响应输出, 并保持与已有 `kv_transfer_params` 模式一致。对于需要扩展相似功能的读者有很强的参考价值。review 中提出的高优先级问题应尽快修复。

功能与动机

PR Body 指出: 目的是为 OpenAI 兼容协议添加 `ec_transfer_params` 顶级字段 (请求输入路由与响应输出), 镜像已有的 `kv_transfer_params` 模式; 同时将 `ECConnectorBase.request_finished()` 接入调度器的 `_free_request()`, 使得 EC Connector 可在请求完成时发出传输参数。

实现拆解

1. 协议层: 在 `ChatCompletionRequest`、`ChatCompletionResponse` 以及 `Completion` 和 `Responses` 对应协议模型中添加 `ec_transfer_params: dict[str, Any] | None` 字段, 并在 `to_sampling_params()` 中将其注入 `extra_args`。
2. Request 构造: 在 `vllm/v1/request.py` 的 `__init__` 中从 `sampling_params.extra_args` 读取 `ec_transfer_params`, 赋值给 `req.ec_transfer_params`。
3. 调度器集成: 在 `Scheduler._free_request()` 中将返回类型从单值元组改为 `(kv_params, ec_params)`, 并调用 `self.ec_connector.request_finished(request)` 获取 EC 参数; 同时添加 `SchedulerInterface.get_ec_connector()` 抽象方法以便外部访问。
4. 引擎输出: 在 `EngineCoreOutput` 和 `RequestOutput` 中添加 `ec_transfer_params` 字段, 在 `make_request_output()` 中传入并最终在响应中体现。
5. Rust 前端: 在 `rust/src/server/src/utils.rs` 增加 `merge_ec_transfer_params()` 函数, 将请求中的 `ec_transfer_params` 合并到 `vllm_xargs` 供引擎核心消费。
6. 环境变量: 新增 `VLLM_EC_SIDE_CHANNEL_HOST` 和 `VLLM_EC_SIDE_CHANNEL_PORT` 环境变量 (通过 `vllm/envs.py`)。
7. 测试: 新增专用单元测试文件, 覆盖请求路由、Request 读取、RequestOutput 聚合、调度器 `_free_request` 以及无 connector 的默认情况; 同时更新现有测试 mock 以适配新的返回类型。

关键文件：

- tests/v1/ec_connector/unit/test_ec_transfer_params.py (模块 传输参数; 类别 test; 类型 test-coverage; 符号 test_ec_transfer_params_routed_to_sampling_params_extra_args, test_request_output_add_propagates_ec_transfer_params, _out, test_request_reads_ec_transfer_params_from_extra_args) : 新增专用测试文件, 覆盖请求路由、Request 读取、RequestOutput 聚合、调度器 _free_request 及无 connector 默认情况, 是验证 ec_transfer_params 流水线的核心测试。
- vllm/v1/core/sched/scheduler.py (模块 调度器; 类别 source; 类型 core-logic; 符号 get_ec_connector) : 调度器核心修改: _free_request 返回元组并调用 ECCConnector.request_finished(), 是参数传递的关键环节。
- rust/src/server/src/utils.rs (模块 Rust 前端; 类别 source; 类型 core-logic; 符号 merge_ec_transfer_params) : Rust 前端新增 merge_ec_transfer_params 函数, 将请求中的 ec_transfer_params 注入 vllm_xargs, 保持与 Python 后端一致。
- vllm/v1/core/sched/interface.py (模块 调度器接口; 类别 source; 类型 core-logic; 符号 get_ec_connector) : 在 SchedulerInterface 中添加 get_ec_connector 抽象方法, 提供统一的 EC Connector 访问接口。
- vllm/entrypoints/openai/chat_completion/protocol.py (模块 协议层; 类别 source; 类型 core-logic) : 在请求和响应模型中添加 ec_transfer_params 字段, 并在 to_sampling_params 中注入到 extra_args, 是参数传递的入口。

关键符号: ECCConnectorBase.request_finished, Scheduler._free_request, Scheduler.get_ec_connector, SchedulerInterface.get_ec_connector, merge_ec_transfer_params, ChatCompletionRequest.to_sampling_params, RequestOutput.add, Request.init, make_request_output

关键源码片段

vllm/v1/core/sched/scheduler.py

调度器核心修改: _free_request 返回元组并调用 ECCConnector.request_finished(), 是参数传递的关键环节。

关键改动集中在 _free_request 方法和 get_ec_connector 方法

```
def _free_request(
    self, request: Request, delay_free_blocks: bool = False
) -> tuple[dict[str, Any] | None, dict[str, Any] | None]:
    assert request.is_finished()
    self._inflight_prefills.discard(request)

    # 先获取 kv connector 的 finished 参数
    connector_delay_free_blocks, kv_xfer_params = self._connector_finished(request)

    # EC Connector: 镜像 KV hook, 必须在释放编码器缓存前调用,
    # 以便 connector 检查 per-request state 并发出 ec_transfer_params 给响应体
    ec_xfer_params: dict[str, Any] | None = None
```

```

if self.ec_connector is not None:
    ec_delay_free, ec_xfer_params = self.ec_connector.request_finished(request)
    connector_delay_free_blocks -= ec_delay_free

self.encoder_cache_manager.free(request)
request_id = request.request_id
self.finished_req_ids.add(request_id)

# ... 延迟释放块逻辑
if not delay_free_blocks:
    self._free_blocks(request)

# 返回 (kv_params, ec_params) 元组
return kv_xfer_params, ec_xfer_params

def get_ec_connector(self) -> ECConnectorBase | None:
    """返回当前调度器使用的 EC Connector 实例。"""
    return self.ec_connector

```

rust/src/server/src/utils.rs

Rust 前端新增 `merge_ec_transfer_params` 函数，将请求中的 `ec_transfer_params` 注入 `vllm_xargs`，保持与 Python 后端一致。

```

/// Merge `ec_transfer_params` into the `vllm_xargs` map, mirroring the Python
/// vLLM behavior where `ec_transfer_params` is injected into `extra_args` for
/// engine-core consumption.
pub fn merge_ec_transfer_params(
    mut xargs: Option<HashMap<String, Value>>,
    ec_transfer_params: Option<&HashMap<String, Value>>,
) -> Option<HashMap<String, Value>> {
    // 如果 ec_transfer_params 存在，将其序列化为 JSON Value 并插入到 xargs 映射中
    if let Some(ec_params) = ec_transfer_params {
        let map = xargs.get_or_insert_with(HashMap::new);
        map.insert(
            "ec_transfer_params".to_string(),
            // 这里假定 ec_params 已经是合法 JSON，unwrap 是安全的
            serde_json::to_value(ec_params).unwrap(),
        );
    }
    xargs
}

```

评论区精华

@gemini-code-assist 指出 `RequestOutput.add` 中 `ec_transfer_params` 被无条件覆盖，可能导致流式输出时之前保存的参数丢失，建议仅在不为 `None` 时更新。@orozery 对是否在响应中包含 `ec_transfer_params` 提出讨论，作者说明该字段用于通知 orchestrator 请求完成及编码大小等信息，直到 EC Events 上游实现。@orozery 还要求将测试改为使用

`create_scheduler` 并将新测试目录加入 CI 配置。

- `RequestOutput.add` 中 `ec_transfer_params` 覆盖问题 (correctness): 建议仅在不为 `None` 时更新
- `extra_args` `None` 访问异常 (correctness): 建议使用 `(sampling_params.extra_args or {}).get()` 安全访问
- 是否在响应中包含 `ec_transfer_params` (design): 保留响应字段, 后续可能通过 EC Events 重构

风险与影响

- 风险:
 1. 数据丢失风险: 当前 `RequestOutput.add()` 无条件将 `ec_transfer_params` 设为新输出块的值, 若后续块为 `None` 则会覆盖前序非 `None` 值, 导致参数丢失。这是前一个 review 指出的高优先级问题。
 2. 空值异常: 在 `vllm/v1/request.py` 中直接调用 `sampling_params.extra_args.get()`, 但 `extra_args` 默认可为 `None`, 将引发 `AttributeError`。
 3. 跨语言一致: Rust 前端与 Python 后端需保持字段名及类型一致, 若后续修改需同步两边。
 4. 测试覆盖: 新增测试虽覆盖主要路径, 但缺少对异常流程 (如 EC Connector 抛出异常) 的处理。
 - 影响: 对使用 EC Connector 进行 `encoder-cache` 分布式服务的用户, 该 PR 使得跨节点传输参数能从请求端传递至引擎调度并通过响应返回, 是 EC Connector 功能完整性的关键一步。改动涉及协议层、调度核心、Rust 前端和输出处理器, 影响面较广, 但均为对现有 `kv_transfer_params` 模式的镜像扩展, 风险可控。
 - 风险标记: 数据丢失风险 (streaming), 空值异常风险, 跨语言同步风险, 测试覆盖待完善

关联脉络

- 暂无明显关联 PR