

PR #42585 完整报告

vllm-project/vllm

[Bugfix][V1] Fix TOCTOU race causing intermittent `EADDRINUSE` on multi-API-server DP startup

合并时间: 2026-05-27 05:06

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/42585>

执行摘要

- 一句话: 修复多 API 服务器启动时的端口竞态条件
- 推荐动作: 值得精读, 尤其适合需要了解多进程端口安全分配和 ZMQ 启动流程的开发者; 设计决策 (延迟端口绑定 vs 预分配) 及 review 中的讨论具有通用借鉴意义。

功能与动机

父进程通过 `get_open_port()` (bind + close) 预分配临时端口, 但子进程直到 5-25 秒后才真正绑定 ZMQ socket。在此窗口内, 其他进程 (包括 vLLM 自身其他端口分配) 可能占用该端口, 导致 `EADDRINUSE`。PR body 明确指出: “Fix: Apply the same `bind-in-child + report-back-via-Pipe` pattern that `DPCoordinator` already uses.”

实现拆解

1. 修改 `get_engine_client_zmq_addr` (`vllm/v1/utils.py`): 移除内部的 `get_open_port()` 调用, 直接返回 `tcp://host:port` (port 为 0 或指定值); 将端口选择的职责交给调用者, 调用者绑定后通过 `getsockopt(zmq.LAST_ENDPOINT)` 获取实际端口。
2. 在 `APIServerProcessManager` 中引入 Pipe 机制 (`vllm/v1/utils.py`): 每个 API 服务器子进程启动时, 在 `client_config` 中附带一个 `multiprocessing.Pipe` 的写端 (`actual_address_pipe`)。子进程绑定 ZMQ socket 后, 通过该 Pipe 发送实际端点字典; 父进程通过新增的 `gather_actual_addresses()` 方法收集所有子进程的地址, 并在超时或子进程崩溃时抛出明确异常。
3. 在 `MPCClient.__init__` 中添加双向适配 (`vllm/v1/engine/core_client.py`): 如果 `client_config` 中包含 `actual_address_pipe`, 则在绑定 socket 后通过 `getsockopt` 获取实际端点并发送; 如果不存在 Pipe (例如单进程模式), 则在绑定后自行解析 `tcp://host:0` 占位符, 就地更新 `addresses` 对象后再启动引擎。
4. 修改 `get_engine_zmq_addresses` (`vllm/v1/engine/utils.py`): 新增 `defer_api_server_ports` 参数 (默认 `True`), 生成 `tcp://host:0` 占位符; 同时为 `handshake_address` 保留旧的 `port=0` 自动分配行为。
5. 集成到 CLI 启动入口 (`vllm/entrypoints/cli/serve.py`): 在创建 `APIServerProcessManager` 后立即调用 `gather_actual_addresses()`, 将实际地址写回 `addresses.inputs` 和 `addresses.outputs`, 再进入 `launch_core_engines` 上下文管理器的引擎握手阶段。Rust 前端通过 `defer_api_server_ports=False` 选择禁用此模式。

关键文件：

- vllm/v1/utils.py (模块 进程管理；类别 source；类型 core-logic；符号 `get_engine_client_zmq_addr`, `gather_actual_addresses`, `APIServerProcessManager.init`, `APIServerProcessManager.shutdown`)：核心变更：移除 `get_engine_client_zmq_addr` 中的端口预分配，新增 `gather_actual_addresses` 方法和 Pipe 初始化逻辑。
- tests/entrypoints/test_api_server_process_manager.py (模块 测试；类别 test；类型 test-coverage；符号 `defer_addresses_stub_worker`, `test_gather_actual_addresses_end_to_end`, `test_gather_actual_addresses_child_crash_before_report`)：新增端到端测试，覆盖正常路径和子进程崩溃场景，验证 Pipe 收集地址的正确性。
- vllm/v1/engine/utils.py (模块 引擎工具；类别 source；类型 core-logic；符号 `get_engine_zmq_addresses`, `_addr`)：修改 `get_engine_zmq_addresses` 以支持延迟端口分配参数，生成 `tcp://host:0` 占位符。
- vllm/v1/engine/core_client.py (模块 客户端核心；类别 source；类型 core-logic；符号 `MPCClient.init`, `AsyncMPCClient.init`)：在 `MPCClient` 中实现 Pipe 报告和占位符解析，确保两种模式都正确获取实际端点。
- vllm/v1/engine/coordinator.py (模块 协调器；类别 source；类型 cleanup；符号 `DPCoordinator.init`)：简化 `bind_address` 函数，移除冗余的 `get_open_port` 调用，使用统一的 `get_engine_client_zmq_addr`。
- vllm/entrypoints/cli/serve.py (模块 CLI 入口；类别 source；类型 core-logic)：集成 `gather_actual_addresses` 调用，将实际地址反馈给引擎握手流程。
- vllm/v1/engine/async_llm.py (模块 异步引擎；类别 source；类型 cleanup)：类型注解调整以配合 `client_addresses` 的泛化。

关键符号： `get_engine_client_zmq_addr`, `gather_actual_addresses`, `APIServerProcessManager.init`, `APIServerProcessManager.shutdown`, `get_engine_zmq_addresses`, `MPCClient.init`, `AsyncMPCClient.init`, `DPCoordinator.init`, `run_multi_api_server`

关键源码片段

vllm/v1/utils.py

核心变更：移除 `get_engine_client_zmq_addr` 中的端口预分配，新增 `gather_actual_addresses` 方法和 Pipe 初始化逻辑。

```
# vllm/v1/utils.py (gather_actual_addresses)
def gather_actual_addresses(
    self,
    timeout: float = 30.0,
) -> tuple[list[str], list[str]]:
    """从每个子进程的 pipe 中读取实际绑定的端点。
```

等待所有子进程报告它们的 ROUTER/PULL 地址。如果子进程在

报告之前退出，pipe 会 EOF，此时抛出 ``RuntimeError``。

```
"""
```

```
if self._address_pipes is None:
    raise RuntimeError("cannot gather addresses without deferring port assignment")
```

```
start = time.monotonic()
actual_inputs: list[str | None] = [None] * len(self._address_pipes)
actual_outputs: list[str | None] = [None] * len(self._address_pipes)
```

```
# 使用 ``ConnectionPoll`` 来在超时内轮询所有 pipe。
pending = set(range(len(self._address_pipes)))
pipes = self._address_pipes[:] # 复制，因为我们在循环中会关闭它们
```

```
while pending and (time.monotonic() - start < timeout):
    for i in list(pending):
        if pipes[i].poll(0):
            msg = pipes[i].recv()
            actual_inputs[i] = msg["input_address"]
            actual_outputs[i] = msg["output_address"]
            pipes[i].close()
            pending.remove(i)
    if pending:
        time.sleep(0.01)
```

```
# 关闭所有剩余的 pipe
for i in pending:
    pipes[i].close()
```

```
if pending:
    failed_indices = sorted(pending)
    raise RuntimeError(
        f"{len(pending)} API server(s) did not report addresses: "
        f"indices {failed_indices}"
    )
```

```
return (
    [addr for addr in actual_inputs if addr is not None], # type: ignore[misc]
    [addr for addr in actual_outputs if addr is not None], # type: ignore[misc]
)
```

tests/entrypoints/test_api_server_process_manager.py

新增端到端测试，覆盖正常路径和子进程崩溃场景，验证 Pipe 收集地址的正确性。

```
# tests/entrypoints/test_api_server_process_manager.py
# 模块级工作进程，必须可被 multiprocessing.spawn 导入（不能是闭包或嵌套函数）
def defer_addresses_stub_worker(listen_address, sock, args, client_config):
    """绑定 ROUTER/PULL socket 并报告实际端点。"""
    ctx = zmq.Context()
    try:
```

```

# 以 ``tcp://host:0`` 方式绑定，内核自动分配空闲端口
in_sock = make_zmq_socket(
    ctx, client_config["input_address"], zmq.ROUTER, bind=True
)
out_sock = make_zmq_socket(
    ctx, client_config["output_address"], zmq.PULL, bind=True
)
# 通过 ``getsockopt(zmq.LAST_ENDPOINT)`` 获取实际端点
pipe = client_config["actual_address_pipe"]
try:
    pipe.send({
        "input_address": in_sock.getsockopt(zmq.LAST_ENDPOINT).decode(),
        "output_address": out_sock.getsockopt(zmq.LAST_ENDPOINT).decode(),
    })
finally:
    pipe.close()
finally:
    in_sock.close(linger=0)
    out_sock.close(linger=0)
    ctx.term()

```

由 pytest 调用的端到端测试

```

def test_gather_actual_addresses_end_to_end():
    host = "127.0.0.1"
    num_servers = 4
    # 生成占位符地址 tcp://host:0
    placeholder_inputs = [
        get_engine_client_zmq_addr(local_only=False, host=host)
        for _ in range(num_servers)
    ]
    placeholder_outputs = [
        get_engine_client_zmq_addr(local_only=False, host=host)
        for _ in range(num_servers)
    ]
    for addr in placeholder_inputs + placeholder_outputs:
        assert addr == f"tcp://{host}:0", addr

    sock = socket.socket()
    manager = APIServerProcessManager(
        listen_address=f"tcp://{host}:0",
        sock=sock,
        args="test_args",
        num_servers=num_servers,
        input_addresses=placeholder_inputs,
        output_addresses=placeholder_outputs,
        target_server_fn=defer_addresses_stub_worker,
    )
    try:
        actual_inputs, actual_outputs = manager.gather_actual_addresses(timeout=15.0)

```

```

finally:
    manager.shutdown()
    sock.close()

assert len(actual_inputs) == num_servers
assert len(actual_outputs) == num_servers
for addr in actual_inputs + actual_outputs:
    # 验证地址是完整格式且端口不是 0
    scheme, parsed_host, port = split_zmq_path(addr)
    assert scheme == "tcp"
    assert port != 0

```

评论区精华

统一新方式 vs 保留旧方式的争论：Robert 认为应全量改用新方式，移除旧分支，使代码更清晰。njhill 解释 `APIServerProcessManager` 目前仅用于多 API 服务器场景，而 `AsyncLLM` 直接使用引擎时不需要，因此保留抽象是合理的。两人同意后续可单独 PR 优化。

类型注解争议：gemini-code-assist[bot] 指出 `client_addresses` 从 `dict[str, str]` 变为包含 `Connection` 对象，导致 `# type: ignore` 的压制。作者最终将 `client_addresses` 类型改为 `dict[str, Any]` 以恢复类型安全。

关键 Bug 发现：gemini 发现 `get_engine_client_zmq_addr` 的行为变更破坏了 `handshake_address` 的逻辑（引擎 handshake 仍需要预先分配端口）。vadiklyutiy 在后续提交中修复，保留 `port=0` 自动分配路径。

socket 绑定误报：gemini 警告 `output_socket` 未显式绑定就调用 `getsockopt`，作者标记为“False positive”——因为 `make_zmq_socket` 在 `bind=True` 时已绑定，此处 socket 正是以 `bind=True` 创建的。

资源泄漏：gemini 建议在关闭 Pipe 后立即释放父端句柄，并在 `shutdown` 中统一清理 `_address_pipes`。作者已采纳。

- 统一新方式 vs 保留旧方式 (design): 当前设计可接受，后续可单独 PR 移除 context manager。
- `client_addresses` 类型注解问题 (style): 作者将类型改为 `dict[str, Any]` 并移除 `type: ignore`。
- `get_engine_client_zmq_addr` 行为变更破坏 `handshake_address` (correctness): 作者在后续提交中为 `handshake_address` 保留 `port=0` 自动分配行为（通过 `get_open_port()` 填充）。
- Socket 未绑定就调用 `getsockopt` 的担忧 (correctness): 作者标记为“False positive”——`make_zmq_socket` 在 `bind=True` 时已绑定 socket，此处 socket 正是用 `bind=True` 创建。
- Pipe 资源泄漏 (performance): 作者在 `gather_actual_addresses` 中已关闭，并在 `shutdown` 中添加清理。

风险与影响

- 风险：回归风险（低）：对于 IPC 路径 (`local_only=True`) 无影响；对于 Rust 前端（已设置 `defer_api_server_ports=False`）行为不变。`get_engine_client_zmq_addr` 的行为变更已适配所有内部调用者。

兼容性风险（中）：`get_engine_client_zmq_addr` 不再自动分配端口，如果外部代码直接使用此函数并依赖其端口分配，可能失效。但该函数被标记为内部 API。

资源泄漏（已解决）：`gather_actual_addresses` 和 `shutdown` 方法都包含了 Pipe 关闭逻辑，通过 CI 验证。

时序风险（低）：`gather_actual_addresses` 设置了 15 秒超时，子进程提前崩溃会立即检测到并抛出 `RuntimeError`，避免死锁。测试覆盖了子进程崩溃场景。

- 影响：用户：多 API 服务器 DP 启动的 `EADDRINUSE` 错误彻底消失；在极端端口压力测试中（仅剩 100 个端口），修复后通过率从 1/28 提升至 50/50。

系统：端口分配模式更健壮，消除了因端口占用导致的启动失败。

团队：代码复杂度略有增加，但模式统一（与 `DPCoordinator` 一致），后续维护成本较低。

- 风险标记：核心路径变更，端口 0 占位符依赖，Rust 前端未适配

关联脉络

- PR #40596 : Issue 评论中提到 #40596 做了相同的修复，但未合并。
- PR #41983 : Issue 评论中提到 #41983 也做了相同的修复，但未合并。