Red Hat Enterprise Linux 9

配置 InfiniBand 和 RDMA 网络

在 Red Hat Enterprise Linux 9 中配置 InfiniBand 和 RDMA 网络的指南

Last Updated: 2022-07-21

Red Hat Enterprise Linux 9 配置 InfiniBand 和 RDMA 网络

在 Red Hat Enterprise Linux 9 中配置 InfiniBand 和 RDMA 网络的指南

Enter your first name here. Enter your surname here.
Enter your organisation's name here. Enter your organisational division here.
Enter your email address here.

法律通告

摘要

本文档描述了 InfiniBand 和远程直接访问(RDMA)是什么以及如何配置 InfiniBand 硬件。另外，本文档解释了如何配置与 InfiniBand 相关的服务。

目录

使开源包含更多

红帽致力于替换我们的代码、文档和 Web 属性中存在问题的语言。我们从这四个术语开始：master、slave、黑名单和白名单。由于此项工作十分艰巨，这些更改将在即将推出的几个发行版本中逐步实施。详情请查看 CTO Chris Wright 的信息。

对红帽文档提供反馈

我们感谢您对文档提供反馈信息。请让我们了解如何改进文档。

- 关于特定内容的简单评论：
  1. 请确定您使用 *Multi-page HTML* 格式查看文档。另外，确定 **Feedback** 按钮出现在文档页的右上方。
  2. 用鼠标指针高亮显示您想评论的文本部分。
  3. 点在高亮文本上弹出的 **Add Feedback**。
  4. 按照显示的步骤操作。
- 要通过 Bugzilla 提交反馈，请创建一个新的 ticket：
  1. 进入 Bugzilla 网站。
  2. 在 Component 中选择 **Documentation**。
  3. 在 **Description** 中输入您要提供的信息。包括文档相关部分的链接。
  4. 点 **Submit Bug**。

第 1 章 了解 INFINIBAND 和 RDMA

InfiniBand 代表两个不同的因素：

- InfiniBand 网络的物理链路协议
- InfiniBand Verbs API，这是 RDMA（remote direct memory access）技术的一个实现

RDMA 提供了跨两个计算机的主要内存访问，而无需涉及操作系统、缓存或存储。通过使用 RDMA，可以实现高吞吐量、低延迟和 CPU 使用率的数据传输。

在典型的 IP 数据传输中，当机器中的某个应用程序向另一台机器上的应用程序发送数据时，在接收层时会出现以下操作：

1. 内核必须接收数据。
2. 内核必须确定该数据是否属于该应用程序。
3. 内核唤醒应用程序。
4. 内核会等待应用程序执行系统调用到内核。
5. 应用程序将内核本身的内部内存空间数据复制到应用程序提供的缓冲中。

此过程意味着，如果主机适配器使用直接内存访问(DMA)或至少两次，则大多数网络流量会被复制到系统的主内存中。另外，计算机执行一些上下文开关以在内核和应用程序上下文间进行切换。这些上下文切换可能会导致 CPU 负载高，并会降低其他任务的速度。

与传统的 IP 通信不同，RDMA 通信会绕过通信过程中的内核干预。这可减少 CPU 开销。RDMA 协议可让主机适配器在数据包进入网络后决定应用程序应该接收的网络以及将其保存到应用程序的内存空间中。主机适配器不将处理发送到内核并将其复制到用户应用程序的内存中，主机适配器直接在应用程序缓冲中放置数据包内容。此过程需要单独的 API、InfiniBand Verbs API 和应用程序需要实施 InfiniBand Verbs API 来使用 RDMA。

Red Hat Enterprise Linux 支持 InfiniBand 硬件和 InfiniBand Verbs API。另外，它支持以下技术在非 InfiniBand 硬件中使用 InfiniBand Verbs API:

- Internet 广域 RDMA 协议(iWARP)：通过 IP 网络实现 RDMA 的网络协议
- RDMA over Converged Ethernet(RoCE)，也称为 InfiniBand over Ethernet(IBoE)：通过以太网实现 RDMA 的网络协议

其他资源

- 配置 RoCE

第 2 章 配置 SOFT-IWARP

这部分解释了有关 iWARP、Soft-iWARP 和 配置 Soft-iWARP 的背景信息。

2.1. IWARP 和 SOFT-IWARP 概述

远程直接内存访问(RDMA)使用互联网 Wide-area RDMA 协议(iWARP)并通过 TCP 进行融合和低延迟数据传输。使用标准以太网交换机和 TCP/IP 堆栈，iWARP 在 IP 子网之间路由流量。这提供了高效使用现有基础架构的灵活性。在 Red Hat Enterprise Linux 中，多个提供商在其硬件网络接口卡中实施 iWARP。例如： **cxgb4**、**irdma**、**qedr** 等。

Soft-iWARP (siw) 是一个基于软件的、用于 Linux 的 iWARP 内核驱动器和用户程序库。它是一个基于软件的 RDMA 设备，在附加到网络接口卡时为 RDMA 硬件提供编程接口。它提供测试和验证 RDMA 环境的简便方法。

2.2. 配置 SOFT-IWARP

软 IWARP(siw)通过 Linux TCP/IP 网络堆栈实施互联网 Wide-area RDMA 协议(iWARP)远程直接内存访问(RDMA)传输。它可让具有标准以太网适配器的系统与 iWARP 适配器或另一个系统互操作，运行 Soft-iWARP 驱动程序，或使用支持 iWARP 的硬件的主机进行互操作。

重要

Soft-iWARP 功能仅作为技术预览提供。红帽产品服务级别协议（SLA）不支持技术预览功能，且其功能可能并不完善，因此红帽不建议在生产环境中使用它们。这些预览可让用户早期访问将来的产品功能，让用户在开发过程中测试并提供反馈意见。

如需有关 技术预览功能支持范围 的信息，请参阅红帽客户门户网站中的技术预览功能支持范围。

要配置 Soft-iWARP，您可以在脚本中使用这个步骤在系统引导时自动运行。

先决条件

- 已安装以太网适配器

流程

1. 安装 **iproute**、**libibverbs**、**libibverbs-utils** 和 **infiniband-diags** 软件包：

```
# dnf install iproute libibverbs libibverbs-utils infiniband-diags
```

2. 显示 RDMA 链接：

```
# rdma link show
```

3. 加载 **siw** 内核模块：

```
# modprobe siw
```

4. 添加一个新的名为 **siw0** 的 **siw** 设备，它使用 **enp0s1** 接口：

```
# rdma link add siw0 type siw netdev enp0s1
```

验证

1. 查看所有 RDMA 链接的状态：

```
# rdma link show

link siw0/1 state ACTIVE physical_state LINK_UP netdev enp0s1
```

2. 列出可用的 RDMA 设备：

```
# ibv_devices

 device                 node GUID
 ------              ----------------
 siw0                0250b6fffea19d61
```

3. 您可以使用 **ibv_devinfo** 工具显示详细的状态：

```
# ibv_devinfo siw0

    hca_id:               siw0
    transport:            iWARP (1)
    fw_ver:               0.0.0
    node_guid:            0250:b6ff:fea1:9d61
    sys_image_guid:       0250:b6ff:fea1:9d61
    vendor_id:            0x626d74
    vendor_part_id:       1
    hw_ver:               0x0
    phys_port_cnt:        1
        port:             1
            state:        PORT_ACTIVE (4)
            max_mtu:      1024 (3)
            active_mtu:   1024 (3)
            sm_lid:       0
            port_lid:     0
            port_lmc:     0x00
            link_layer:   Ethernet
```

第 3 章 配置 ROCE

本节介绍 RDMA over Converged Ethernet(RoCE)的背景信息，以及如何更改默认的 RoCE 版本。

请注意，有不同的厂商，比如 Mellanox、Broadcom 和 QLogic 都提供 RoCE 硬件。

3.1. ROCE 协议版本概述

RoCE 是一个网络协议，它允许通过以太网进行远程直接访问(RDMA)。

以下是不同的 RoCE 版本：

RoCE v1

RoCE 版本 1 协议是一个以太网链路层协议，带有 ethertype **0x8915**，它允许同一以太网广播域中的任何两个主机间的通信。

RoCE v2

RoCE 版本 2 协议在 IPv4 或 IPv6 协议的 UDP 上存在。对于 RoCE v2，UDP 目标端口号为 **4791**。

RDMA_CM 设置客户端和服务器之间用来传输数据的可靠连接。RDMA_CM 为建立连接提供了一个与 RDMA 传输相关的接口。这个通信使用特定的 RDMA 设备和基于消息的数据传输。

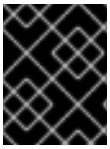

重要

不支持在客户端中使用 RoCE v2 的不同版本，并在服务器中使用 RoCE v1。在这种情况下，将服务器和客户端都配置为通过 RoCE v1 进行通信。

RoCE v1 在 Data Link layer(Layer 2)工作，它只支持同一网络中的两台计算机的通信。默认情况下，RoCE v2 可用。它适用于网络层(Layer 3)。RoCE v2 支持数据包路由，以便提供与多个以太网的连接。

其他资源

- 临时更改默认 RoCE 版本

3.2. 临时更改默认 ROCE 版本

在客户端中使用 RoCE v2 协议，并不支持服务器上的 RoCE v1。如果您的服务器中硬件只支持 RoCE v1，请将您的客户端配置为使用 RoCE v1 与服务器通信。这部分论述了如何在对 Mellanox ConnectX-5 Infiniband 设备使用 **mlx5_0** 驱动程序的客户端中强制实施 RoCE v1。

请注意，本节中描述的更改只在重启主机前临时进行。

先决条件

- 客户端使用 RoCE v2 协议的 InfiniBand 设备
- 服务器使用只支持 RoCE v1 的 InfiniBand 设备

流程

1. 创建 **/sys/kernel/config/rdma_cm/*mlx5_0*/** 目录：

```
# mkdir /sys/kernel/config/rdma_cm/mlx5_0/
```

2. 显示默认 RoCE 模式：

```
# cat /sys/kernel/config/rdma_cm/mlx5_0/ports/1/default_roce_mode

RoCE v2
```

3. 将默认 RoCE 模式改为版本 1:

```
# echo "IB/RoCE v1" > /sys/kernel/config/rdma_cm/mlx5_0/ports/1/default_roce_mode
```

第 4 章 配置核心 RDMA 子系统

这部分论述了如何配置 **rdma** 服务，并增加允许用户在系统中固定的内存量。

4.1. 使用 SYSTEMD 链接文件重命名 IPOIB 设备

默认情况下，内核会命名 IP over InfiniBand (IPoIB) 设备，例如 **ib0**、**ib1** 等等。为避免冲突，请创建一个 **systemd** 链接文件，以创建永久和有意义的名称，如 **mlx4_ib0**。

先决条件

- 已安装 InfiniBand 设备

流程

1. 显示设备 **ib0** 的硬件地址：

```
# ip addr show ib0

7: ib0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 65520 qdisc fq_codel state UP
group default qlen 256
    link/infiniband 80:00:0a:28:fe:80:00:00:00:00:00:00:00:f4:52:14:03:00:7b:e1:b1 brd
00:ff:ff:ff:ff:12:40:1b:ff:ff:00:00:00:00:00:00:ff:ff:ff:ff
    altname ibp7s0
    altname ibs2
    inet 172.31.0.181/24 brd 172.31.0.255 scope global dynamic noprefixroute ib0
       valid_lft 2899sec preferred_lft 2899sec
    inet6 fe80::f652:1403:7b:e1b1/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
```

2. 为了将 MAC 地址为 **80:00:0a:28:fe:80:00:00:00:00:00:00:00:f4:52:14:03:00:7b:e1:b1** 的接口命名为 **mlx4_ib0**，创建带有以下内容的 **/etc/systemd/network/70-custom-ifnames.link** 文件：

```
[Match]
MACAddress=80:00:0a:28:fe:80:00:00:00:00:00:00:00:f4:52:14:03:00:7b:e1:b1

[Link]
Name=mlx4_ib0
```

此链接文件与 MAC 地址相匹配，并将网络接口重命名为 **Name** 参数中设置的名称。

验证

1. 重启主机：

```
# reboot
```

2. 验证链接文件中指定的 MAC 地址的设备是否已分配给 **mlx4_ib0** ：

```
# ip addr show mlx4_ib0

7: mlx4_ib0: <BROADCAST,MULTICAST,UP,LOWER_UP> mtu 65520 qdisc fq_codel state
UP group default qlen 256
```

```
    link/infiniband 80:00:0a:28:fe:80:00:00:00:00:00:00:f4:52:14:03:00:7b:e1:b1 brd
00:ff:ff:ff:ff:12:40:1b:ff:ff:00:00:00:00:00:00:ff:ff:ff:ff
    altname ibp7s0
    altname ibs2
    inet 172.31.0.181/24 brd 172.31.0.255 scope global dynamic noprefixroute mlx4_ib0
       valid_lft 2899sec preferred_lft 2899sec
    inet6 fe80::f652:1403:7b:e1b1/64 scope link noprefixroute
       valid_lft forever preferred_lft forever
```

其他资源

- **systemd.link(5)** man page

4.2. 增加用户可以在系统中固定的内存量

远程直接内存访问(RDMA)操作需要固定物理内存。因此，内核不允许将内存写入交换空间。如果用户固定太多内存，系统会耗尽内存，并且内核会终止进程来释放更多内存。因此，内存固定是一个特权操作。

如果非 root 用户运行大型 RDMA 应用程序，则可能需要增加这些用户可在系统中的内存量。这部分论述了如何为 **rdma** 组配置无限内存。

流程

- 以 **root** 用户身份，使用以下内容创建文件 **/etc/security/limits.conf** ：

```
@rdma soft memlock unlimited
@rdma hard memlock unlimited
```

验证

1. 在编辑 **/etc/security/limits.conf** 文件后，以 **rdma** 组的成员登录。
   请注意，当用户登录时，Red Hat Enterprise Linux 会应用更新的 **ulimit** 设置。
2. 使用 **ulimit -l** 命令显示限制：

```
$ ulimit -l
unlimited
```

   如果命令返回 **unlimited**，用户可以获得无限数量的内存。

其他资源

- **limits.conf(5)** 手册页

4.3. 启用通过 RDMA(NFSORDMA) 的 NFS

远程直接内存访问(RDMA)服务在 Red Hat Enterprise Linux 9 中启用了 RDMA 的硬件自动工作。

流程

1. 安装 **rdma-core** 软件包：

```
# dnf install rdma-core
```

2. 验证在 **/etc/rdma/modules/rdma.conf** 文件中注释掉了带有 **xprtrdma** 和 **svcrdma** 的行：

```
# NFS over RDMA client support
xprtrdma
# NFS over RDMA server support
svcrdma
```

3. 在 NFS 服务器中，创建目录 **/mnt/nfsordma** 并将其导出到 **/etc/exports** ：

```
# mkdir /mnt/nfsordma
# echo "/mnt/nfsordma *(fsid=0,rw,async,insecure,no_root_squash)" >> /etc/exports
```

4. 在 NFS 客户端上，使用服务器 IP 地址挂载 nfs-share，例如 **172.31.0.186** ：

```
# mount -o rdma,port=20049 172.31.0.186:/mnt/nfs-share /mnt/nfs
```

5. 重启 **nfs-server** 服务：

```
# systemctl restart nfs-server
```

其他资源

- RFC5667 标准

第 5 章 配置 INFINIBAND 子网管理器

所有 InfiniBand 网络都必须运行子网管理器才能正常工作。即使两台机器没有使用交换机直接进行连接，也是如此。

有可能有一个以上的子网管理器。在那种情况下，当主子网管理器出现故障时，另外一个作为从网管理器的系统会接管。

大多数 InfiniBand 交换机都包含一个嵌入式子网管理器。然而，如果您需要一个更新的子网管理器，或者您需要更多控制，请使用 Red Hat Enterprise Linux 提供的 **OpenSM** 子网管理器。

详情请参阅安装 OpenSM 子网管理器

第 6 章 配置 IPOIB

默认情况下，InfiniBand 不使用 IP 进行通信。但是，IP over InfiniBand(IPoIB)在 InfiniBand 远程直接访问(RDMA)网络之上提供 IP 网络模拟层。这允许现有未修改的应用程序通过 InfiniBand 网络传输数据，但如果应用程序可以原生使用 RDMA，则性能较低。

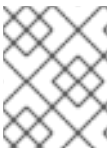

注意

在 RHEL 8 和更新的版本中，从 ConnectX-4 开始的 Mellanox 设备默认使用增强 IPoIB 模式（仅数据报）。在这些设备中不支持连接模式。

6.1. IPOIB 通讯模式

IPoIB 设备可在 **Datagram** 或 **Connected** 模式中配置。不同之处在，IPoIB 层试图使用什么类型的队列对在通信的另一端的机器中打开：

- 在 **Datagram** 模式中，系统会打开一个不可靠、断开连接的队列对。
  这个模式不支持大于 InfiniBand 链路层的最大传输单元(MTU)的软件包。在传输数据时，IPoIB 层在 IP 数据包之上添加了一个 4 字节 IPoIB 标头。因此，IPoIB MTU 比 InfiniBand link-layer MTU 小 4 个字节。因为 **2048** 是一个常见的 InfiniBand 链路层 MTU， **Datagram** 模式中的通用 IPoIB 设备 MTU 为 **2044**。

- 在 **Connected** 模式中，系统会打开一个可靠、连接的队列对。
  这个模式允许消息大于 InfiniBand link-layer MTU。主机适配器处理数据包分段和重新装配。因此，在 **Connected** 模式中，从 Infiniband 适配器发送的消息没有大小限制。但是，由于 **data** 字段和 TCP/IP **header** 字段，存在一个 IP 数据包限制。因此， **Connected** 模式中的 IPoIB MTU 是 **65520** 字节。

  Connected 模式性能更高，但是消耗更多内核内存。

虽然系统被配置为使用 **Connected** 模式，系统仍然会使用 **Datagram** 模式发送多播流量，因为 InfiniBand 交换机和光纤无法在 **Connected** 模式中传递多播流量。另外，当主机没有配置为使用 **Connected** 模式时，系统会返回 **Datagram** 模式。

当运行一个应用程序，这个应用程序在接口上发送最大到 MTU 的多播数据时，将接口设置为处于 **Datagram** 模式，或对应用程序进行配置，使其对发送的数据包的大小有一个上限，以适用于 datagram-sized 的数据包。

6.2. 了解 IPOIB 硬件地址

ipoib 设备有 **20** 个字节硬件地址，它由以下部分组成：

- 前 4 个字节是标志和队列对号。

- 接下来的 8 个字节是子网前缀
  默认子网前缀为 **0xfe:80:00:00:00:00:00:00**。设备连接到子网管理器后，设备会更改此前缀以匹配配置的子网管理器。

- 最后 8 个字节是 IPoIB 设备附加到的 InfiniBand 端口的全局唯一标识符(GUID)。

注意

因为前 12 个字节可以改变，请不要在 **udev** 设备管理器规则中使用它们。

6.3. 使用 NMCLI 命令配置 IPOIB 连接

nmcli 命令行工具控制 NetworkManager 并使用 CLI 报告网络状态。

先决条件

- 在服务器上安装 InfiniBand 设备
- 加载对应的内核模块

流程

1. 创建 InfiniBand 连接，在 **Connected** 传输模式中使用 **mlx4_ib0** 接口，以及最大 MTU **65520** 字节：

```
# nmcli connection add type infiniband con-name mlx4_ib0 ifname mlx4_ib0 transport-mode Connected mtu 65520
```

2. 您还可以将 **0x8002** 设置为 **mlx4_ib0** 连接的 **P_Key** 接口：

```
# nmcli connection modify mlx4_ib0 infiniband.p-key 0x8002
```

3. 要配置 IPv4 设置，设置 **mlx4_ib0** 连接的静态 IPv4 地址、网络掩码、默认网关和 DNS 服务器：

```
# nmcli connection modify mlx4_ib0 ipv4.addresses 192.0.2.1/24
# nmcli connection modify mlx4_ib0 ipv4.gateway 192.0.2.254
# nmcli connection modify mlx4_ib0 ipv4.dns 192.0.2.253
# nmcli connection modify mlx4_ib0 ipv4.method manual
```

4. 要配置 IPv6 设置，设置 **mlx4_ib0** 连接的静态 IPv6 地址、网络掩码、默认网关和 DNS 服务器：

```
# nmcli connection modify mlx4_ib0 ipv6.addresses 2001:db8:1::1/32
# nmcli connection modify mlx4_ib0 ipv6.gateway 2001:db8:1::fffe
# nmcli connection modify mlx4_ib0 ipv6.dns 2001:db8:1::fffd
# nmcli connection modify mlx4_ib0 ipv6.method manual
```

5. 激活 **mlx4_ib0** 连接：

```
# nmcli connection up mlx4_ib0
```

6.4. 使用 NM-CONNECTION-EDITOR 配置 IPOIB 连接

nmcli-connection-editor 应用程序使用 GUI 配置和管理 NetworkManager 存储的网络连接。

先决条件

- 在服务器上安装 InfiniBand 设备
- 加载相应的内核模块
- 已安装 **nm-connection-editor** 软件包

流程

1. 输入命令：

```
$ nm-connection-editor
```

2. 点击 **+** 按钮来添加一个新的连接。
3. 选择 **InfiniBand** 连接类型并点 **Create**。
4. 在 **InfiniBand** 选项卡中：
   a. 如果您想更改连接名称。
   b. 选择传输模式。
   c. 选该设备。
   d. 如果需要，设置 MTU。
5. 在 **IPv4 Settings** 选项卡中，配置 IPv4 设置。例如，设置静态 IPv4 地址、网络掩码、默认网关和 DNS 服务器：

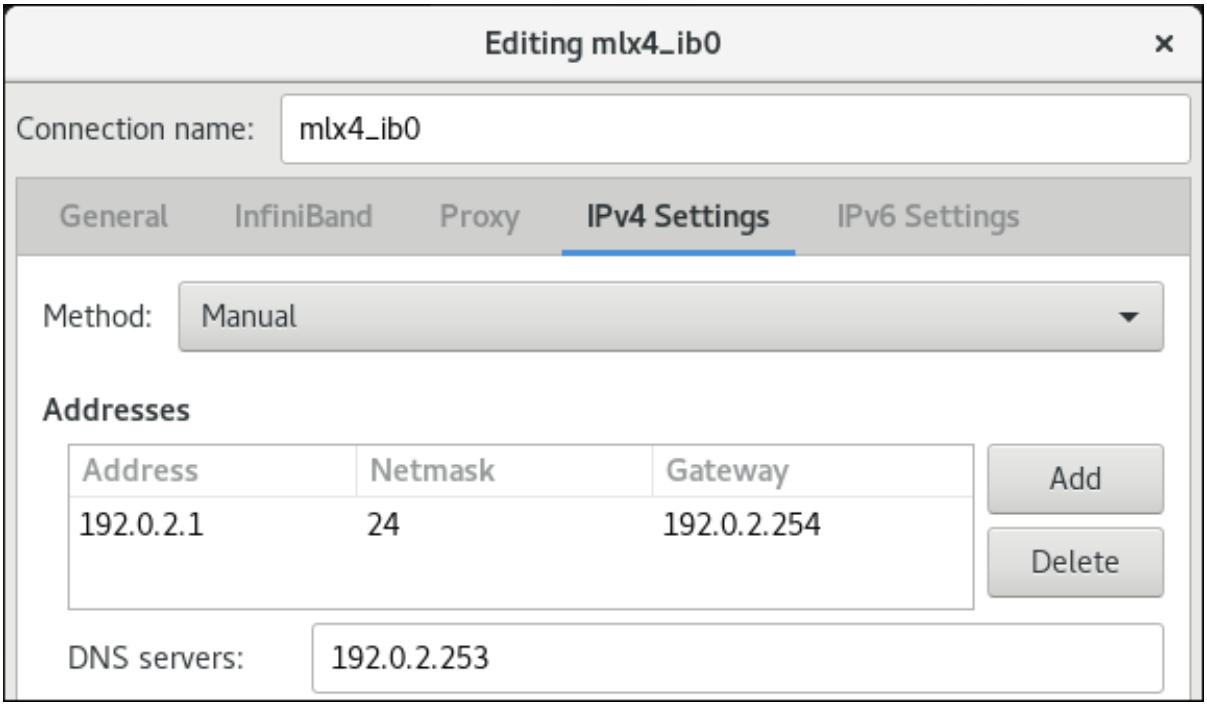

6. 在 **IPv6 设置** 选项卡上，配置 IPv6 设置。例如，设置静态 IPv6 地址、网络掩码、默认网关和

6. 在 **IPv6 设置** 选项卡上，配置 IPv6 设置。例如，设置静态 IPv6 地址、网络掩码、默认网关和 DNS 服务器：

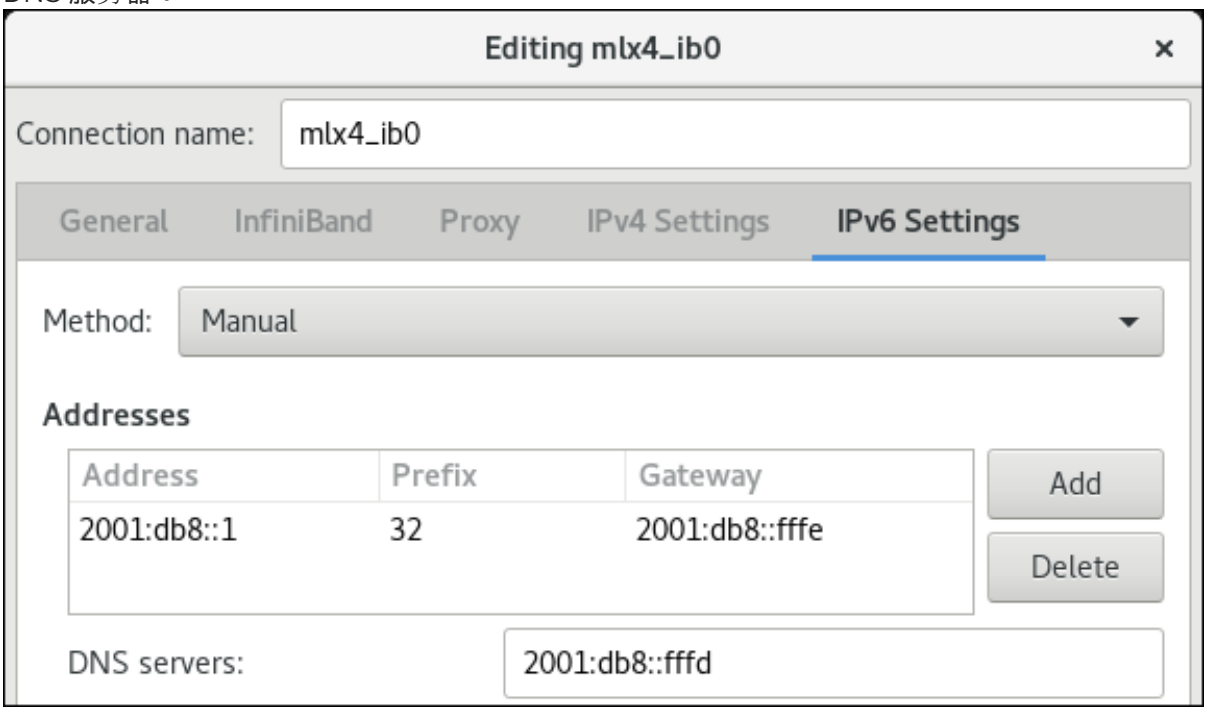

7. 点 **Save** 保存 team 连接。

8. 关闭 **nm-connection-editor**。

9. 您可以设置 **P_Key** 接口。因为 **nm-connection-editor** 中没有此设置，所以您必须在命令行中设置此参数。
例如，要将 **0x8002** 设置为 **mlx4_ib0** 连接的 **P_Key** 接口：

```
# nmcli connection modify mlx4_ib0 infiniband.p-key 0x8002
```

第 7 章 测试 INFINIBAND 网络

本节提供测试 InfiniBand 网络的步骤。

7.1. 测试早期 INFINIBAND RDMA 操作

这部分论述了如何测试 InfiniBand 远程直接访问(RDMA)操作。

注意

这部分只适用于 InfiniBand 设备。如果您使用基于 IP 的设备，比如互联网 Wide-area Remote Protocol(iWARP)或 RDMA over Converged Ethernet(RoCE)或 InfiniBand over Ethernet(IBoE)设备，请参阅：

- 使用 ping 程序测试 IPoIB
- 配置 IPoIB 后使用 iperf3 测试 RDMA 网络

先决条件

- 配置了 **rdma** 服务
- 安装了 **libibverbs-utils** 和 **infiniband-diags** 软件包

流程

1. 列出可用的 InfiniBand 设备：

```
# ibv_devices

    device                 node GUID
    ------              ----------------
    mlx4_0              0002c903003178f0
    mlx4_1              f4521403007bcba0
```

2. 显示 **mlx4_1** 设备的信息：

```
# ibv_devinfo -d mlx4_1

hca_id: mlx4_1
        transport:                  InfiniBand (0)
        fw_ver:                     2.30.8000
        node_guid:                  f452:1403:007b:cba0
        sys_image_guid:             f452:1403:007b:cba3
        vendor_id:                  0x02c9
        vendor_part_id:             4099
        hw_ver:                     0x0
        board_id:                   MT_1090120019
        phys_port_cnt:              2
                port:   1
                        state:              PORT_ACTIVE (4)
                        max_mtu:            4096 (5)
                        active_mtu:         2048 (4)
                        sm_lid:             2
```

```
            port_lid:          2
            port_lmc:          0x01
            link_layer:        InfiniBand

        port:   2
            state:             PORT_ACTIVE (4)
            max_mtu:           4096 (5)
            active_mtu:        4096 (5)
            sm_lid:            0
            port_lid:          0
            port_lmc:          0x00
            link_layer:        Ethernet
```

3. 显示 **mlx4_1** 设备的状态：

```
# ibstat mlx4_1

CA 'mlx4_1'
    CA type: MT4099
    Number of ports: 2
    Firmware version: 2.30.8000
    Hardware version: 0
    Node GUID: 0xf4521403007bcba0
    System image GUID: 0xf4521403007bcba3
    Port 1:
        State: Active
        Physical state: LinkUp
        Rate: 56
        Base lid: 2
        LMC: 1
        SM lid: 2
        Capability mask: 0x0251486a
        Port GUID: 0xf4521403007bcba1
        Link layer: InfiniBand
    Port 2:
        State: Active
        Physical state: LinkUp
        Rate: 40
        Base lid: 0
        LMC: 0
        SM lid: 0
        Capability mask: 0x04010000
        Port GUID: 0xf65214fffe7bcba2
        Link layer: Ethernet
```

4. **ibping** 程序通过配置参数来 ping InfiniBand 地址并以客户端/服务器运行。

   a. 要启动服务器模式 **-S** 在端口号 **-P** 上带有 **-C** InfiniBand 证书颁发机构(CA)名称：

   ```
   # ibping -S -C mlx4_1 -P 1
   ```

   b. 要启动客户端模式，在主机的端口号 **-P** 上发送一些数据包 **-c**，使用带有 **-L** Local Identifier (LID) 的 **-C** InfiniBand certificate authority (CA) 名称：

   ```
   # ibping -c 50 -C mlx4_0 -P 1 -L 2
   ```

其他资源

- **ibping(8)** 手册页

7.2. 使用 PING 程序测试 IPOIB

配置了 IPoIB 后，使用 **ping** 程序发送 ICMP 数据包来测试 IPoIB 连接。

先决条件

- 两个 RDMA 主机在带有 RDMA 端口的同一个 InfiniBand 光纤中连接
- 这两个主机中的 IPoIB 接口使用同一子网中的 IP 地址配置

流程

- 使用 **ping** 程序将五个 ICMP 数据包发送到远程主机的 InfiniBand 适配器：

```
# ping -c5 192.0.2.1
```

7.3. 配置 IPOIB 后使用 IPERF3 测试 RDMA 网络

在以下示例中，大型缓冲区大小用于执行 60 秒测试，用于测量使用 **iperf3** 实用程序的两个主机之间的最大吞吐量，并充分利用两个主机之间的带宽和延迟。

先决条件

- ipoIB 在两个主机上配置

流程

1. 要在系统中运行 **iperf3** 作为服务器，定义一个时间间隔，以提供定期带宽更新 **-i** 以侦听，作为一个服务器 **-s**，等待客户端连接的响应：

```
# iperf3 -i 5 -s
```

2. 要作为客户端在另一个系统上运行 **iperf3**，请定义一个间隔，提供定期带宽更新 **-i** 连接到侦听的服务器 **-c** 连接到 IP 地址 **192.168.2.2** 和 **-t** 秒（以秒为单位）：

```
# iperf3 -i 5 -t 60 -c 192.168.2.2
```

3. 使用以下命令：

   a. 在作为服务器的系统中显示测试结果：

```
# iperf3 -i 10 -s
-----------------------------------------------------------
Server listening on 5201
-----------------------------------------------------------
Accepted connection from 192.168.2.3, port 22216
[5] local 192.168.2.2 port 5201 connected to 192.168.2.3 port 22218
[ID] Interval           Transfer     Bandwidth
[5]   0.00-10.00  sec  17.5 GBytes  15.0 Gbits/sec
```

```
[5]  10.00-20.00  sec  17.6 GBytes  15.2 Gbits/sec
[5]  20.00-30.00  sec  18.4 GBytes  15.8 Gbits/sec
[5]  30.00-40.00  sec  18.0 GBytes  15.5 Gbits/sec
[5]  40.00-50.00  sec  17.5 GBytes  15.1 Gbits/sec
[5]  50.00-60.00  sec  18.1 GBytes  15.5 Gbits/sec
[5]  60.00-60.04  sec  82.2 MBytes  17.3 Gbits/sec
- - - - - - - - - - - - - - - - - - - - - - - - -
[ID] Interval           Transfer     Bandwidth
[5]   0.00-60.04  sec  0.00 Bytes    0.00 bits/sec  sender
[5]   0.00-60.04  sec   107 GBytes  15.3 Gbits/sec  receiver
```

b. 在作为客户端的系统中显示测试结果：

```
# iperf3 -i 1 -t 60 -c 192.168.2.2

Connecting to host 192.168.2.2, port 5201
[4] local 192.168.2.3 port 22218 connected to 192.168.2.2 port 5201
[ID] Interval           Transfer     Bandwidth       Retr  Cwnd
[4]   0.00-10.00  sec  17.6 GBytes  15.1 Gbits/sec    0   6.01 MBytes
[4]  10.00-20.00  sec  17.6 GBytes  15.1 Gbits/sec    0   6.01 MBytes
[4]  20.00-30.00  sec  18.4 GBytes  15.8 Gbits/sec    0   6.01 MBytes
[4]  30.00-40.00  sec  18.0 GBytes  15.5 Gbits/sec    0   6.01 MBytes
[4]  40.00-50.00  sec  17.5 GBytes  15.1 Gbits/sec    0   6.01 MBytes
[4]  50.00-60.00  sec  18.1 GBytes  15.5 Gbits/sec    0   6.01 MBytes
- - - - - - - - - - - - - - - - - - - - - - - - -
[ID] Interval           Transfer     Bandwidth       Retr
[4]   0.00-60.00  sec   107 GBytes  15.4 Gbits/sec    0   sender
[4]   0.00-60.00  sec   107 GBytes  15.4 Gbits/sec        receiver
```

其他资源

- **iperf3** man page