

OpenStackに最適な MidoNetの最新利用事例と オープンソースコミュニティの紹介



鈴木孝彰
システムエンジニア
ミドクラジャパン株式会社


アジェンダ

- ✓ ミドクラ会社紹介
- ✓ MidoNetとは
- ✓ OpenStack + MidoNetの活用事例
- ✓ MidoNetのテクノロジー
- ✓ オープンソースになったMidoNet
- ✓ まとめ

ミドクラって誰？ ～ミドクラ会社紹介～

ミドクラについて

✓「ネットワーク仮想化ソフトウェア」を開発、販売している会社です



ミドクラについて

- ✓ 東京にも開発拠点をもち、フロントからダイレクトに開発部隊にエスカレーション
- ✓ タイムゾーンが異なる3拠点に展開し、問題が発生した際も迅速な対応可能




MidoNetとは？

OpenStackに最適な ネットワーク仮想化ソリューション


OpenStack
Neutronと連携

 midonet



source: <http://www.openstack.org/software/>

スケーラビリティおよび耐障害性を持つ OpenStackネットワークを実現



**OpenStackやMidoNetは、商用利用
できるの？**

～ OpenStack + MidoNetの活用事例～

OpenStack + MidoNetの活用事例

マネージド
クラウドサービス

“物理機器なしで
ロードバランサー
を実現。コストを
押さえ、スモール
スタート可能”

パブリック
クラウドサービス

“フルオートメー
ション可能なパブ
リッククラウド
サービスを実現”

プライベート
クラウド

“製品開発、営業デ
モなど、多様な用
途に柔軟に使える
プライベートクラ
ウドを構築”

← 広く商用利用実績がでています →

マネージドクラウドサービス


KVH様 “プライベートクラウド TypeS”

サービス概要

- 高価なネットワーク機器の購入やマニュアル作業による設定無しで、FW, LB, L23/スイッチングなどのネットワーク機能を実現
- 従来サービス比で、20%程度のコスト削減を見込む
- プライベートクラウドを小規模から構築しやすく

MidoNet 採用理由

- OpenStack Neutronとの互換性
- L4LBをはじめとしたネットワークサービスの充実



KVHホームページより抜粋

パブリッククラウドサービス

Zetta IOテクノロジー様 “zetta io”

サービス概要

- ITサービス企業が商用環境で利用できるパブリッククラウドをノルウェーで提供
- 全機能が自動化され、ユーザーによるセルフサービスが可能
- MidoNetを使い、仮想ネットワークサービス (L2, L3, FW, LB)を提供

MidoNet 採用理由


- 「顧客ニーズに合わせた迅速な製品化、安定性、拡張性」というzetta.ioの要件を満たした製品
- PoCを通じ、ネットワーク仮想化ソフトウェアで最も優れていると判断



プライベートクラウド ミドクラ “MidoCloud”

サービス概要

- ミドクラ社内用のプライベートクラウド
- 2014/01から運用実績
- HavanaからIcehouseへのアップグレード実績あり
ダウンタイムなし！
- システム物理構成
 - サーバー：30台
 - 物理コア640
 - ストレージ：120TB
 - 10Gスイッチ40ポート2台



powered by  **RED HAT®
ENTERPRISE LINUX®
OPENSTACK® PLATFORM**




MidoNetのテクノロジー

エッジオーバレイ

ソフトウェアで仮想L3/L2ネットワークを構築

Logical Topology




エッジオーバレイ

ソフトウェアで仮想L3/L2ネットワークを構築

Logical Topology


vPort

```
[root@sanktgallen ~]# midonet-cli
midonet> list router
router router0 name MidoNet Provider Router state up
midonet> list bridge
bridge bridge0 name internal-bitisle state up
bridge bridge1 name external state up
bridge bridge2 name loadrunner-test-network state up
```



分散アーキテクチャ

- “エッジ”にコントローラ機能をおくことで、無駄なトラフィックが発生しない



分散アーキテクチャ

- “エッジ”にコントローラ機能をおくことで、無駄なトラフィックが発生しない

Watch/modify

```
Host: id=3cedc510-10af-4a08-b21e-350d1a85ab5b
```

```
name=bitburger
```

```
isAlive=true
```

```
addresses:
```

```
vport-host-if-bindings:
```

```
VirtualPortMapping{virtualPortId=08111e47-e732-4c4b-98d4-a62160219c8e, localDeviceName='tap08111e47-e7' }
```

```
VirtualPortMapping{virtualPortId=f7b997d5-1782-409c-a854-0118e630377f, localDeviceName='tapf7b997d5-17' }
```

```
VirtualPortMapping{virtualPortId=65ce6468-a5f0-407c-b471-80ce7e944f56, localDeviceName='tap65ce6468-a5' }
```

```
VirtualPortMapping{virtualPortId=362d5c69-755e-4ab9-9a56-39f5e24edc64, localDeviceName='tap362d5c69-75' }
```

```
VirtualPortMapping{virtualPortId=3815df3b-dac2-4ae0-871b-32724cfdd01a, localDeviceName='tap3815df3b-da' }
```

```
VirtualPortMapping{virtualPortId=efb0de12-dbb2-47af-94ff-791c26d1177d, localDeviceName='tapefb0de12-db' }
```

```
VirtualPortMapping{virtualPortId=dc3ecab2-4b1d-4309-a3f8-3b393f9a5988, localDeviceName='tapdc3ecab2-4b' }
```

```
VirtualPortMapping{virtualPortId=1eee2665-45c8-45df-946b-0c99272a78f9, localDeviceName='tap1eee2665-45' }
```

```
VirtualPortMapping{virtualPortId=b2c192ed-fceb-45ff-ab0d-7ff6dca023a3, localDeviceName='tapb2c192ed-fc' }
```

```
VirtualPortMapping{virtualPortId=fala453d-bab2-432e-b635-5c522c895e78, localDeviceName='tapfala453d-ba' }
```

```
VirtualPortMapping{virtualPortId=2d9eec6c-c49f-49cc-ab33-30a20326cc0d, localDeviceName='tap2d9eec6c-c4' }
```


Open vSwitch Datapath

Host

Add/remove flows




分散アーキテクチャ

GRE/VXLAN Tunneling



分散アーキテクチャ

```
G [root@sanktgallen ~]# midonet-cli
midonet> list host
host host0 name carlsberg alive true
host host1 name stone alive true
host host2 name schneider alive true
host host3 name optimator alive true
host host4 name bachmayer alive true
host host5 name magnumdry alive true
host host6 name namashibori alive true
host host7 name krombacher alive true
host host8 name paulaner alive true
host host9 name franziskaner alive true
host host10 name hacker-pschorr alive true
host host11 name nelson alive true
host host12 name erdinger alive true
host host13 name urquell alive true
host host14 name preminger alive true
host host15 name warsteiner alive true
host host16 name becks alive true
host host17 name sanktgallen alive true
host host18 name yebisu alive true
host host19 name bitburger alive true
```



分散アーキテクチャ


GRE/VXLAN Tunneling

midonet v1.7.0 Search network...

- Dashboard
- Hosts** 1
- Tunnel Zones
- Tenants
- Routers
- Bridges
- Chains
- Vtaps


7 results Filter list

Status	UUID	Name	IP
Up	00b7ada6	mngw3-02	
Up	3cf33e85	mngw03-022	
Up	5f4274a6	openstack-icehouse-midonet03.novalocal	
Up	c56bada6	compute3-01	
Up	f245c582	mngw3-01	
Down	f9f4f7d5	mngw3-02	
Up	f9f4f7d5	compute3-02	



スケーラビリティの評価

- 外部NWを經由して8VMに同時接続した時のスループットを測定.
- 外部ネットワークを1本、2本、3本と増やした時のスループットを測定し、分散アーキテクチャによるスケーラビリティを確認.



スケーラビリティの評価 (OpenStack標準OpenvSwitch)



- 外部ネットワーク1本

870Mbps

- 外部ネットワーク3本


870Mbps

トラフィックを自動的に分散することはできない




スケーラビリティの評価 (MidoNet)

- 3本でトラフィック分散 "2.6" Gbps
- アップリンク本数は必要に応じて"自由に増速が可能"




耐障害性の評価

- インターネット回線を順に落とした時のスループットの変化を確認
- インターネット回線を復旧させた時のスループットの変化を確認




耐障害性の評価 (OpenStack標準OpenvSwitch)

- 別々のルータに稼動しているルータは1つダウンしても **自動切替されない**



耐障害性の評価 (MidoNet)

- インターネット回線ダウン、自動でフェイルオーバー
 - インターネット回線アップ、自動で切り戻る
- 帯域測定結果（下記は平均値）



話したい事はたくさんあります！しかしながら

MidoNet is now Open!

- <http://www.midonet.org>

A screenshot of the MidoNet website homepage. The background is a blurred image of people in a meeting. In the top left corner is the MidoNet logo, which consists of a blue hexagon with white dots around it and the text "midonet" in a lowercase, sans-serif font. To the right of the logo is a dark navigation bar with white text links: "HELP | QUICK START | RESOURCES | BLOG | WIKI | DOCS". Below the navigation bar, the main heading "Open-source network virtualization" is displayed in a large, white, sans-serif font. Underneath the heading, a paragraph of white text reads: "MidoNet is an Apache licensed production grade network virtualization software for Infrastructure-as-a-Service (IaaS) clouds." At the bottom left of the page, there is a prominent blue button with rounded corners and white text that says "Get Started in Minutes".

midonet

HELP | QUICK START | RESOURCES | BLOG | WIKI | DOCS

Open-source network virtualization

MidoNet is an Apache licensed production grade network virtualization software for Infrastructure-as-a-Service (IaaS) clouds.

Get Started in Minutes

皆さんの環境で自由に動かします！

Step 1 : Download Midostack

Clone the midostack repository

```
git clone http://github.com/midonet/midostack
```

Step 2 : Run Midostack

```
cd ./midostack
```

Time to run it, this can take awhile, so grab a coffee and come back later.

```
./midonet_stack.sh
```

開発コミュニティに参加しよう！

Want to Contribute?

GitHub

github.com/midonet



#midonet on freenode



lists.midonet.org



[View Complete Contribution Guide](#)

ミドクラ トレーニングを提供開始！

2コースを提供中！

MKT101

OpenStack ファンダメンタルズ

これからOpenStackを使ってクラウド環境を構築するエンジニアが、OpenStackの基礎的な考え方を理解し、OpenStackの各コンポーネントの機能や関連性といった全体構造について深く理解するための基礎コースです。

MKT102

OpenStack ネットワーキングと
MidoNet

OpenStack コンポーネントの中でも、最も理解が難しいと言われているネットワーク部分にフォーカスした中級者向けコースです。OpenStack Neutronの基礎、デフォルトのOVSプラグイン、Neutron Plug-inのミドクラのMidoNetの機能、設定方法、など、についてエクササイズを交えながら深く学ぶことができます。

詳しくはミドクラブースにお越しく下さい！

- お問い合わせ先：training@midokura.com -

仮想ネットワークを作ってみたい方、お試しください！



まとめ

まとめ

- MidoNetはOpenStackネットワークングに最適なネットワーク仮想化ソフトウェアです
- OpenStackとMidoNetで、柔軟なプライベートクラウドが、小さい規模から構築できます
- OpenStackおよびネットワークングを基礎から学びたい方に、トレーニングを提供しています
- MidoNetはオープンソースになったので、自由に触ってみてください！



Mellanoxが提供する OpenStack最新ソリューション

株式会社アルティマ

北島佑樹

2015/2/27

本資料に含まれる測定データは一例であり、測定構成や条件によって変わることがあります。

また、本資料はMellanox Technologies社の公式見解を表すものではありません。

The results in this documents may differ for the configurations or/and conditions.

This documents does not reflect the official views of Mellanox Technologies.

- ▶ Mellanox紹介
 - ◆ 会社概要
 - ◆ 製品紹介
- ▶ OpenStack最新ソリューション
 - ◆ ミドクラxHWオフロード
- ▶ まとめ

- ▶ サーバ・ストレージエリア向け広帯域・低レイテンシーなインターコネクト市場のリーディングプロバイダー
 - ◆ InfiniBand : FDR(56Gbps)、EDR(100Gbps)..coming soon
 - ◆ Ethernet : 10/40/56GbE
 - ◆ 共通ハードウェアでInfiniBand / Ethernetをサポート

- ▶ 本社・従業員数
 - ◆ ヨークニアム（イスラエル）、サニーベール（米国）
 - ◆ 全世界で1652人の従業員（2014年9月末時点）


- ▶ 安定した財務基盤
 - ◆ 2011年度の売上 : \$259.3M
 - ◆ 2012年度の売上 : \$500.8M
 - ◆ 2013年度の売上 : \$390.9M
 - ◆ 2014年度の売上 : \$463.6M



Mellanox社 製品ラインアップ



- ▶ サーバ・ストレージエリア向け広帯域・低レイテンシーのインターコネクト市場のリーディングプロバイダー



Comprehensive End-to-End InfiniBand and Ethernet Portfolio



※資料中の図はメラノックス社提供資料です

Ethernetスイッチラインアップ

SX1036: 36 X 40/56G
The Ideal 40GbE ToR/Aggregation


SX1710: 36 X 40/56G
Intel Xeon Dual Core base system

NEW

SX1024: 48 X 10G + 12 X 40/56G
Non-blocking 10GbE → 40GbE ToR

SX1016: 64 X 10G
Highest density 10GbE ToR

SX1012: 12 X 40/56G(or Up to 48 X 10G)
Ideal storage/Database 10/40GbE Switch



- ▶ Highest Capacity in 1RU
 - ◆ 4TB Switching Capacity
 - ◆ Full non-blocking
- ▶ Unique Value Proposition
 - ◆ VPI: Ethernet and IB support
 - ◆ 10/40/56GbE
 - ◆ L2/L3 Feature set

- ▶ Latency
 - ◆ 220ns L2 latency
 - ◆ 330ns L3 latency
- ▶ Power (SX1036)
 - ◆ 83Watt (full 40GE rate)
 - ◆ 2.3W per 40GbE interface

ネットワークカード(NIC)ラインアップ



型番	MCX311A-XCCT	MCX312B-XCCT	MCX313A-BCCT	MCX314A-BCCT
ポート	Single 10GbE	Dual 10GbE	Single /10/40/56GbE	Dual /10/40/56GbE
コネクタ	SFP+	SFP+	QSFP	QSFP
ケーブル	ダイレクトアタッチカッパー、光ファイバ			
ホストバス	PCIe 3.0			
特長	VXLAN/NVGRE オフロード, RDMA, SR-IOV, 各種オフロード(CheckSUM offload, TCP Segmentaion offload, Stateless offload)			
対応OS	RHEL, SLES, Microsoft Windows Sever, FreeBSD, Ubuntu, VMWare ESXi			

Mellanoxがもたらす サーバ/ストレージネットワークの高速化

高い性能とオーバーレイオフロードエンジンやRDMAに対応した業界トップクラスのNICカード

ConnectX³
PRO



仮想ネットワークにおける
CPU負荷をNICにオフロード

ストレージネットワークにおける
データ通信をRDMAにより高速化



MellanoxのOpenStack向け ソリューションの紹介



×



Strong Partnership for OpenStack



OpenStack Distribution



Network Virtualization



Software Defined Storage



オーバーレイネットワークのHWオフロード



▶ オーバーレイネットワーク

◆ メリット

- オーバーレイ(Tunneling Protocol)により、拡張性、柔軟性、リソースの稼働率向上を実現

◆ 現在の課題

- VXLAN/NVGREの処理に**CPUリソース**が使われるため、アプリケーション**性能の劣化**、**統合率低下**などのリスクが懸念される

▶ ConnectX-3 ProのVXLAN/NVGREオフロード

- ◆ オーバーレイネットワーク用HWオフロードエンジンを搭載
- ◆ VXLAN/NVGRE高速化
- ◆ CPUのオーバーヘッドを劇的に削減

オーバーレイネットワークにおける
理想的なネットワーク基盤を実現可能


- ▶ Mellanox社は10/40GE向け、スイッチシステム、NIC製品を提供
 - ◆ 業界トップクラスの性能とコスト競争力

- ▶ エッジオーバーレイのHWオフロード
 - ◆ CPU負荷の低減
 - ◆ 高い性能効率と収容率の実現

- ▶ 仮想化ネットワークソフトとの連携
 - ◆ オーバーレイ型SDNの導入にはHWオフロードは必須！！
 - ◆ midonetとのソリューションで柔軟で高速なOpenStack基盤を提供

※メラノックスブースでデモ説明対応中

実際どうなの!? VXLANオフロード ～VXLANオフロードの勘所～




▶ 理由

- ◆ VXLANオフロードの観点ではどちらでもサポートだが、
- ◆ サーバとの相性でUbuntu14.04は断念
- ◆ CentOS7 → 3.10.0-123.el7

評価環境

- ▶ CPU : 1CPU(12core) ··· Xeon 2.40GHz (Fujitsu RX200S8)
- ▶ MEM : 18GB
- ▶ OS : CentOS7 (Kernel : 3.10.0-123.el7.x86_64)
- ▶ ConnectX-3 Pro (FW:2.33.5000)



- ▶ RHEL7(CentOS7)ではin-boxでドライバサポート
- ▶ 今回は、Mellanoxから提供されるドライバを使用
 - ◆ Mellanox OFED v2.4-1
 - ◆ http://www.mellanox.com/page/products_dyn?product_family=26

```
# ethtool -i enp4s0  
driver: mlx4_en  
version: 2.4-1.0.0 (Jan 13 2015)  
firmware-version: 2.33.5000
```

RDO PackStack or スクラッチ (or Devstack)



▶ 理由

- ◆ 評価環境に自由度を持たせるためにはスクラッチから構築がベター
- ◆ OpenStackの構成が理解できる
- ◆ OpenStackコミュニティのマニュアル通りに動きます！
 - OpenStack Juno使用

▶ 苦労した点

- ◆ Personal Issue

midostack or スクラッチ

▶ 理由

- ◆ midostackは複数ノード構成を作れない
 - 最近、複数ノード構築ツールでoriduruができたようです。
 - <https://github.com/midonet/orizuru>
- ◆ midonetを理解するため

- ▶ midonetのお試しであれば"midostack"

Step 1 : Download Midostack

Clone the midostack repository

```
git clone http://github.com/midonet/midostack
```

Step 2 : Run Midostack

```
cd ./midostack
```

Time to run it, this can take awhile, so grab a coffee and come back later.

```
./midonet_stack.sh
```

<http://www.midonet.org/#quickstart>

- ▶ マニュアルがRHEL用のため、OpenStackマニュアルとの整合性がない



Documentation

MidoNet Documentation in Online (HTML) and Downloadable PDF format can be found below.

[Quick Start Guide: Ubuntu 14.04 / Juno](#)

[Quick Start Guide: RHEL 7 / Juno \(RDO\)](#)

[Quick Start Guide: Ubuntu 14.04 / Icehouse](#)

[Quick Start Guide: RHEL 7 / Icehouse](#)

[Operation Guide](#)

[Reference Architecture](#)

[REST API](#)

[Developer Documentation \(GitHub\)](#)

- ▶ ネットワーク、インスタンス作成時、Security Groupエラーが発生

原因

- ◆ Neutronデフォルトプラグインが有効(L2,L3,OVS etc...)
- ◆ OpenStackマニュアルのコピペによるHuman Error...
- ◆ midonetプラグインを正確に入力しましょう

/etc/neutron/neutron.conf

```
[DEFAULT]
```

```
...
```

```
core_plugin = midonet.neutron.plugin.MidonetPluginV2
```

▶ midonetサービスが立ち上がらない 原因

- ◆ NSDBノードのZookeeperがエラー
- ◆ 1ノードで立ち上げようとしていたためNG
- ◆ Zookeeperは3ノード構成がデフォルト

※今回はソースコードからインストールし1ノードで構成することで回避

ZooKeeper Installation

1. Install ZooKeeper packages

```
# yum install zookeeper zkdump
```

2. Configure ZooKeeper

a. Common Configuration

Edit the `/etc/zookeeper/zoo.cfg` file to contain the following:

```
server.1=controller:2888:3888  
server.2=network:2888:3888  
server.3=compute1:2888:3888
```

VXLAN設定 (Mellanox)

- ▶ デフォルトでオフロードはEnable

```
# ethtool -k enp130s0 | grep udp  
tx-udp_tnl-segmentation: on
```

- ▶ オフロードEnable / Disableの変更方法

```
# ethtool -K enp130s0 tx-udp_tnl-segmentation off
```

VXLAN設定 (midonet)



- ▶ midonetのデータパス "tnvxlan-overlay"を使います

```
# mm-dpctl --show-dp midonet
Datapath name : midonet
Datapath index : 6
Datapath Stats:
  Flows :0
  Hits :1147
  Lost :0
  Misses:211
Port #0 "midonet" Internal
Port #1 "tngre-overlay" Gre
Port #2 "tnvxlan-overlay" VXLan
Port #3 "tnvxlan-vtep" VXLan
Port #4 "tap4f973dca-6d" NetDev
Port #5 "tap5052daea-da" NetDev
```

▶ VM間通信でVXLANのトンネルを張る設定が必要

```
midonet> create tunnel-zone name vxlan-tz type vxlan  
tzone0
```

```
midonet> list tunnel-zone  
tzone tzone0 name vxlan-tz type vxlan
```

```
midonet> tunnel-zone tzone0 add member host host0 address 192.168.100.201  
zone tzone1 host host0 address 192.168.100.201  
midonet> tunnel-zone tzone0 add member host host1 address 192.168.100.202  
zone tzone1 host host1 address 192.168.100.202
```


```
midonet> tunnel-zone tzone0 list member  
zone tzone1 host host0 address 192.168.100.201  
zone tzone1 host host1 address 192.168.100.202
```

- ▶ OpenStackダッシュボードの操作で動きます
 - ◆ 「ネットワーク作成」 → 「インスタンス作成」 → 「ネットワークアサイン」

VXLAN HWオフロードの性能データ



本資料に含まれる測定データは一例であり、条件によって変わることがあります。
また、本資料はMellanox Technologies社の公式見解を表すものではありません。




HWオフロード
スループット性能

✓ **2.2倍**

HWオフロード
CPU負荷率

✓ **52%削減**



テスト環境
OS : CentOS7 (3.10.0-123)
OpenStack : Juno
midonet : midolman-2015.01-0.1.rc0
Driver : Mellanox OFED ver2.4.1
Bench Tool : iPerf v2.0.5

ミドクラ鈴木さんにOpenStack Ubuntu環境の
テストサマリをご紹介いただきます

MidoNet
+
Mellanox VXLAN offload

MidoNet VXLAN


2014/06~




- 開発者によるVXLANコード追加
- VXLAN通信テスト
- VXLANオフロード機能テスト

*テストの為に物理環境を用意しました。

テスト環境



テスト環境




OSの選択

- RHEL/CentOS6.5 plus 3.14 kernel
- Ubuntu 12.04 plus 3.10 kernel
- この時はCentOSを選択



Mellanox 40G NIC driverの選択

- Kernel 3.14 inbox driver
- Mellanox OFED Driver
 - *WEBから入手可能.



40Gポートが表示されない。

```
root@mlnx01:~# ifconfig -a
em1      Link encap:Ethernet  HWaddr 40:f2:e9:0b:41:3c
         BROADCAST MULTICAST  MTU:1500  Metric:1
         RX packets:0 errors:0 dropped:0 overruns:0 frame:0
         TX packets:0 errors:0 dropped:0 overruns:0 carrier:0
         collisions:0 txqueuelen:1000
         RX bytes:0 (0.0 B)  TX bytes:0 (0.0 B)
         Memory:a8580000-a85a0000

em2      Link encap:Ethernet  HWaddr 40:f2:e9:0b:41:3d
         inet addr:192.168.100.193  Bcast:192.168.100.255  Mask:255.255.255.0
         inet6 addr: fe80::42f2:e9ff:fe0b:413d/64  Scope:Link
         UP BROADCAST RUNNING MULTICAST  MTU:8888  Metric:1
         RX packets:1198107 errors:0 dropped:0 overruns:0 frame:0
         TX packets:1387662 errors:0 dropped:0 overruns:0 carrier:0
         collisions:0 txqueuelen:1000
         RX bytes:175380048 (175.3 MB)  TX bytes:173903881 (173.9 MB)
         Memory:a85a0000-a85c0000
```

*しかしながら、ちゃんとPCIデバイスは認識されている。


```
root@mlnx01:~# lspci | grep Mellanox
11:00.0 Network controller: Mellanox Technologies MT27520 Family [ConnectX-3 Pro]
```

40Gポートが表示されない.


原因: Infinibandモードだった.

```
root@mlnx01:~# cat /sys/bus/pci/devices/0000:11:00.0/mlx4_port1
auto (eth)
root@mlnx01:~# cat /sys/bus/pci/devices/0000:11:00.0/mlx4_port2
auto (ib)
```


MidoNet VXLAN通信の確認



MidoNet VXLAN通信の確認



```
ping/ssh 192.168.11.5 OK  
ping/ssh 192.168.11.6 OK
```


VXLANオフロードの有効化

```
root@mlnx01:~# cat /etc/modprobe.d/mlx4.conf
# mlx4_core gets automatically loaded, load mlx4_en also (LP: #1115710)
options mlx4_core log_num_mgm_entry_size=-1 debug_level=1
```

```
root@mlnx01:~# cat /etc/modprobe.d/mlnx.conf
# Module parameters for MLNX_OFED kernel modules
blacklist mlx4_core
blacklist mlx4_en
blacklist mlx5_core
blacklist mlx5_ib
```


```
[ 3475.361329] mlx4_core 0000:11:00.0: Device managed flow steering support
[ 3475.361345] mlx4_core 0000:11:00.0: Device managed flow steering IPoIB support
[ 3475.361369] mlx4_core 0000:11:00.0: TCP/IP offloads/flow-steering for VXLAN support
[ 3475.361378] mlx4_core 0000:11:00.0: Device managed flow steering VLAN tag mode support
[ 3476.641412] mlx4_core 0000:11:00.0: Steering mode is: Device managed flow steering, oper_log_mgm_entry_size = 1
```

VM間通信がとてつもなく遅い



iperf: 1~3”M”bps

そもそもサーバ間での速度はどうか



iperf: **21Gbps**


PCIe 3.0 x16速度の確認

```
11:00.0 Network controller: Mellanox Technologies MT27520 Family [ConnectX-3 Pro]
Subsystem: Mellanox Technologies Device 0003
Control: I/O- Mem+ BusMaster+ SpecCycle- MemWINV- VGASnoop- ParErr+ Stepping- SERR- FastB2B- DisINTx+
Status: Cap+ 66MHz- UDF- FastB2B- ParErr- DEVSEL=fast >TAbort- <TAbort- <MAbort- >SERR- <PERR- INTx-
Latency: 0, Cache Line Size: 64 bytes
Interrupt: pin A routed to IRQ 32
Region 0: Memory at a8300000 (64-bit, non-prefetchable) [size=1M]
Region 2: Memory at aa800000 (64-bit, prefetchable) [size=8M]
Expansion ROM at <ignored> [disabled]

LnkSta: Speed 8GT/s, Width x8, TrErr- Train- SlotClk+ DLActive- BWMgmt- ABWMgmt-
```


* CPUの制限で5GT/sだったのでCPUを交換.

そもそもサーバ間での速度はどうか



iperf: **37Gbps**

やっぱりVM間通信がとてつもなく遅い



iperf: 1~3“M”bps

MidoNet開発者によるコード変更

```
commit c9d544701189d54510edf2f6662f8ab30db00ee7
```

```
Merge: b42487d 5e7580a
```

```
Author: Hugo Benichi <hugo@midokura.com>
```


```
Date: Tue Jun 17 16:47:17 2014 +0200
```

```
Merge topics 'vxlan_tunnelling', 'vxlan'
```


```
* changes:
```

```
Fixing HBT leak when failing to create a DpPort  
Per tunnel route tunnelling output action
```

通信速度改善された（しかし？）



北島さんのテスト環境




iperf: 9~11Gbps

Ubuntu 14.04で試してみることに



テスト環境 (Ubuntu14.04)



VM間通信 (Ubuntu14.04環境)

[協力ありがとうございます]

アルティマ北島さん、Canonical 松本さん

前回同様 **2.4 ~ 3.0Gbps**

NICドライバ設定 の確認

CentOS		Ubuntu	
Features for enp130s0:	✓	Features for p1p1:	✓
rx-checksumming: on	✓	rx-checksumming: on	✓
tx-checksumming: on	✓	tx-checksumming: on	✓
tx-checksum-ipv4: on	✓	tx-checksum-ipv4: on	✓
tx-checksum-ip-generic: off [fixed]	✓	tx-checksum-ip-generic: off [fixed]	✓
tx-checksum-ipv6: on	✓	tx-checksum-ipv6: on	✓
tx-checksum-fcoe-crc: off [fixed]	✓	tx-checksum-fcoe-crc: off [fixed]	✓
tx-checksum-sctp: off [fixed]	✓	tx-checksum-sctp: off [fixed]	✓
scatter-gather: on	✓	scatter-gather: on	✓
tx-scatter-gather: on	✓	tx-scatter-gather: on	✓
tx-scatter-gather-fraglist: off [fixed]	✓	tx-scatter-gather-fraglist: off [fixed]	✓
tcp-segmentation-offload: on	✓	tcp-segmentation-offload: on	✓
tx-tcp-segmentation: on	✓	tx-tcp-segmentation: on	✓
tx-tcp-ecn-segmentation: off [fixed]	✓	tx-tcp-ecn-segmentation: off [fixed]	✓
tx-tcp6-segmentation: on	✓	tx-tcp6-segmentation: on	✓
udp-fragmentation-offload: off [fixed]	✓	udp-fragmentation-offload: off [fixed]	✓
generic-segmentation-offload: on	✓	generic-segmentation-offload: on	✓
generic-receive-offload: on	✓	generic-receive-offload: on	✓
large-receive-offload: off	✓	large-receive-offload: off	✓
rx-vlan-offload: on	✓	rx-vlan-offload: on	✓
tx-vlan-offload: on [fixed]	✓	tx-vlan-offload: on	✓
ntuple-filters: off	✓	ntuple-filters: off	✓
receive-hashing: on	✓	receive-hashing: on	✓
highdma: on [fixed]	✓	highdma: on [fixed]	✓
rx-vlan-filter: on [fixed]	✓	rx-vlan-filter: on [fixed]	✓
vlan-challenged: off [fixed]	✓	vlan-challenged: off [fixed]	✓
tx-lockless: off [fixed]	✓	tx-lockless: off [fixed]	✓
netns-local: off [fixed]	✓	netns-local: off [fixed]	✓
tx-gso-robust: off [fixed]	✓	tx-gso-robust: off [fixed]	✓
tx-fcoe-segmentation: off [fixed]	✓	tx-fcoe-segmentation: off [fixed]	✓
tx-gre-segmentation: off [fixed]	✓	tx-gre-segmentation: off [fixed]	✓
tx-ipip-segmentation: off [fixed]	✓	tx-ipip-segmentation: off [fixed]	✓
tx-sit-segmentation: off [fixed]	✓	tx-sit-segmentation: off [fixed]	✓
tx-udp_tnl-segmentation: on	✓	tx-udp_tnl-segmentation: on	✓
tx-mpls-segmentation: off [fixed]	✓	tx-mpls-segmentation: off [fixed]	✓
fcoe-mtu: off [fixed]	✓	fcoe-mtu: off [fixed]	✓
tx-nocache-copy: on	✓	tx-nocache-copy: on	✓
loopback: off	✓	loopback: off	✓
rx-fcs: off [fixed]	✓	rx-fcs: off [fixed]	✓
rx-all: off [fixed]	✓	rx-all: off [fixed]	✓
tx-vlan-stag-hw-insert: off [fixed]	✓	tx-vlan-stag-hw-insert: off [fixed]	✓
rx-vlan-stag-hw-parse: off [fixed]	✓	rx-vlan-stag-hw-parse: off [fixed]	✓
rx-vlan-stag-filter: off [fixed]	✓	rx-vlan-stag-filter: off [fixed]	✓
		t2-fwd-offload: off [fixed]	✓

Mellanoxエンジニアによるアップデート

 **Ubuntu**
linux package

Overview Code **Bugs** Blueprints Translations Answers

Mellanox updates for Trusty

Bug #1400127 reported by  Eyal Perry on 2014-12-07

This bug affects 1 person

***現在の最新カーネルにアップデートすると適用される。**

Affects	Status	Importance	Assigned to
▶  linux (Ubuntu)	In Progress 	High	 Chris J Arges
▶  Trusty	Fix Released 	High	 Chris J Arges
▶  Utopic	Fix Released 	High	 Chris J Arges

 Also affects project   Also affects distribution/package  Nominate for series

Bug Description


SRU Justification:

[Impact]
Users of Mellanox `mlx4_{core,en}` drivers may be missing hardware enablement features.

[Test Case]
Test Mellanox hardware and ensure functionality with `mlx4_{core,en}` drivers.


[Fix]
As described below, and summarized in Comment #5.

テスト環境(オフロード無し Ubuntu14.04)



iperf: **7.2Gbps**

テスト環境(オフロード有り Ubuntu14.04)



iperf: 8~10.2Gbps

今後の課題

- 40Gbpsを使い切りたい
(複数のVM間通信).
- KernelやNIC Driverの組み合わせや環境の違いによっては, 期待している性能速度を出せない場合があるので解決していきたい.