OpenStack Days Tokyo 2016
7th July 14:40 – 15:20 4F B-2

shaping tomorrow with you

Newtonでのベアメタルは何が違う？～開発内容の紹介とVMとの機能面のギャップについて～

富士通株式会社 プラットフォームソフトウェア事業本部 Linux開発統括部

古川 勇志郎
椎名 宏徳

自己紹介（1/2）

古川 勇志郎 / Yushiro Furukawa

- 富士通株式会社 所属
  - プライベートクラウドの運用管理ソフトウェアの開発
  - FUJITSU Cloud Service K5の開発
- 現在はOpenStack Neutron/Ironic にて、以下の開発に従事：

1. ベンダープラグイン（ML2）の設計開発
2. ベアメタルサーバのマルチテナント対応
3. ベアメタルサーバのセキュリティグループ対応
4. ネットワークパケットログ採取APIの設計開発
5. FWaaS v2の開発

自己紹介（2/2）

椎名 宏徳 / Hironori Shiina

- 富士通株式会社 所属
  - ミッションクリティカル分野でのミドルウェア開発を経験
- 現在はOpenStack Nova/Ironic にて、以下の開発に従事：

1. NovaにNMI送信のAPIを追加
2. ベアメタルサーバのマルチテナント対応
3. ベアメタルサーバのコンソール対応

アジェンダ

1. OpenStack Ironicとは
2. 目指すべき世界に向けて
3. 開発内容紹介
   - □ 導入フェーズ（配備）
   - □ 正常時運用フェーズ
   - □ 異常時運用フェーズ
4. コミュニティ状況

OpenStack Ironicとは？

- **物理マシンの配備を行うコンポーネント**
  ベアメタル(BM: Bare Metal)プロビジョニング
- **テナント利用者はNova経由でベアメタルサーバを配備可能**

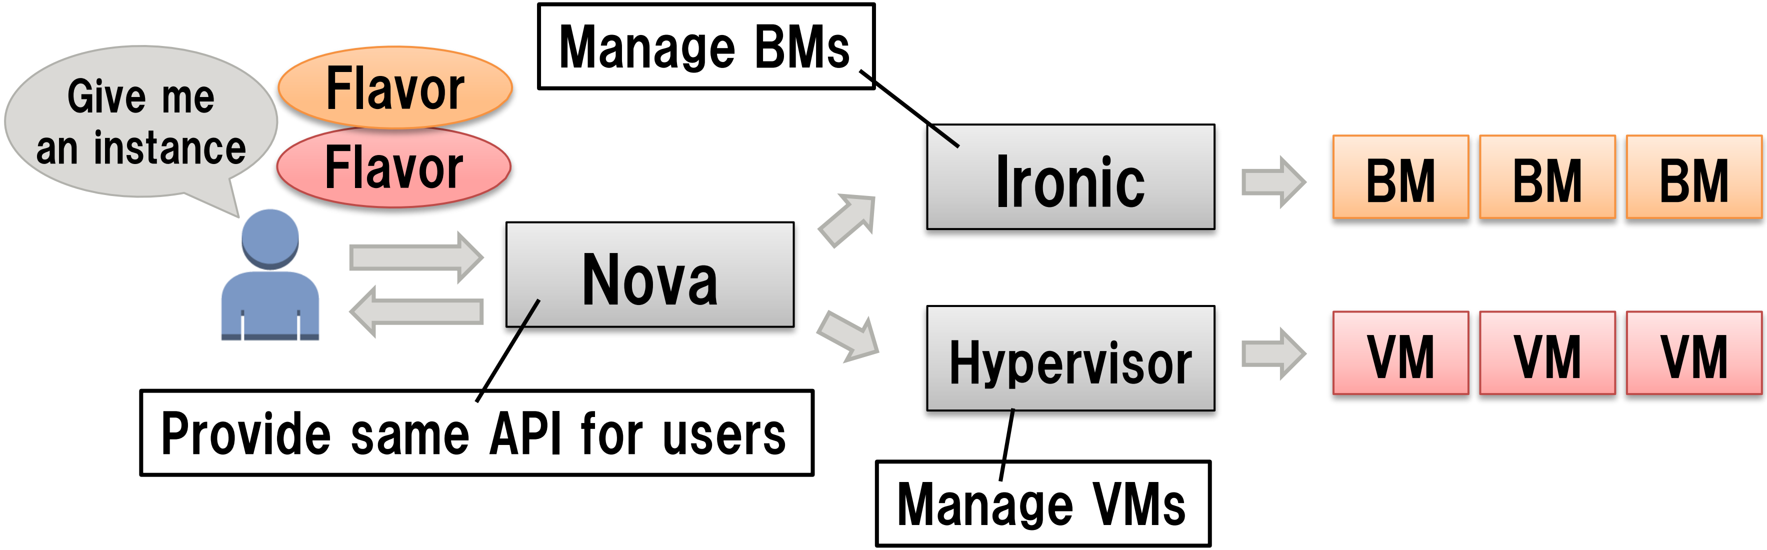
Manage BMs

Give me
an instance

Flavor

Flavor

Nova

Ironic

BM

BM

BM

Hypervisor

VM

VM

VM

Provide same API for users

Manage VMs

Ironicのコンポーネント

- Ironic-API ：REST APIの受け口。管理者のみ利用可能
- Ironic-Conductor: Ironicの中枢。ドライバ呼び出しやDB操作を行う
- Drivers: サーバ毎の差異を吸収する仕組み。OOB経由でBMCを制御
  - BMC: Baseboard Management Controller →サーバ管理用コントローラ
  - OOB: Out Of Band → BMC制御用のネットワーク

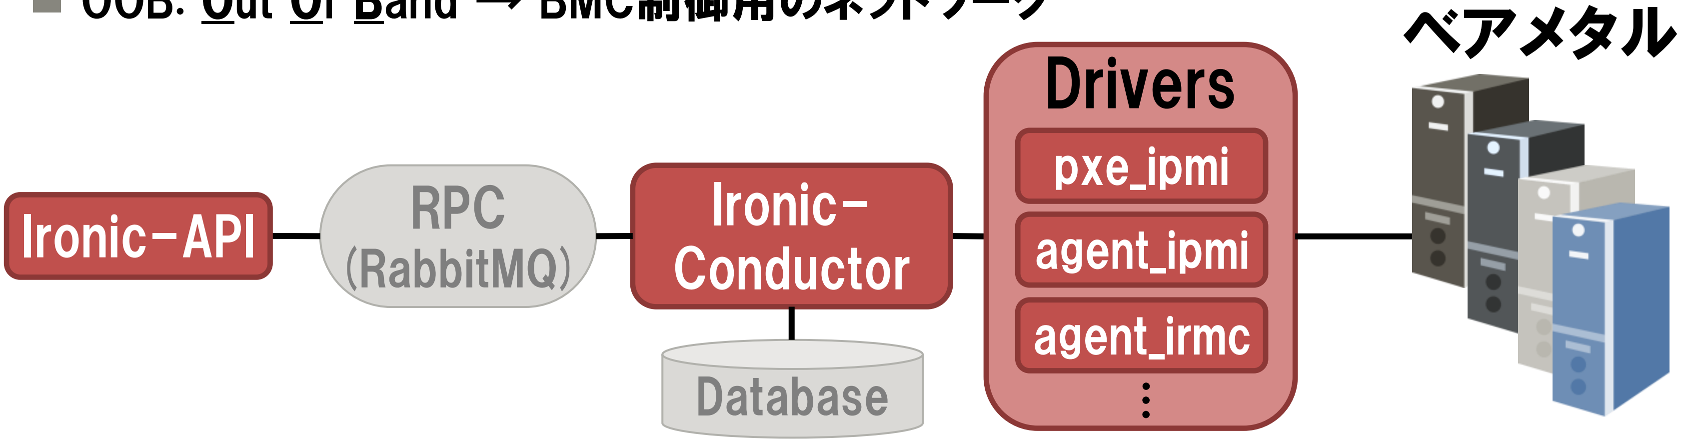

なぜベアメタルサービスが必要なのか？

■オンプレミス → クラウドの普及

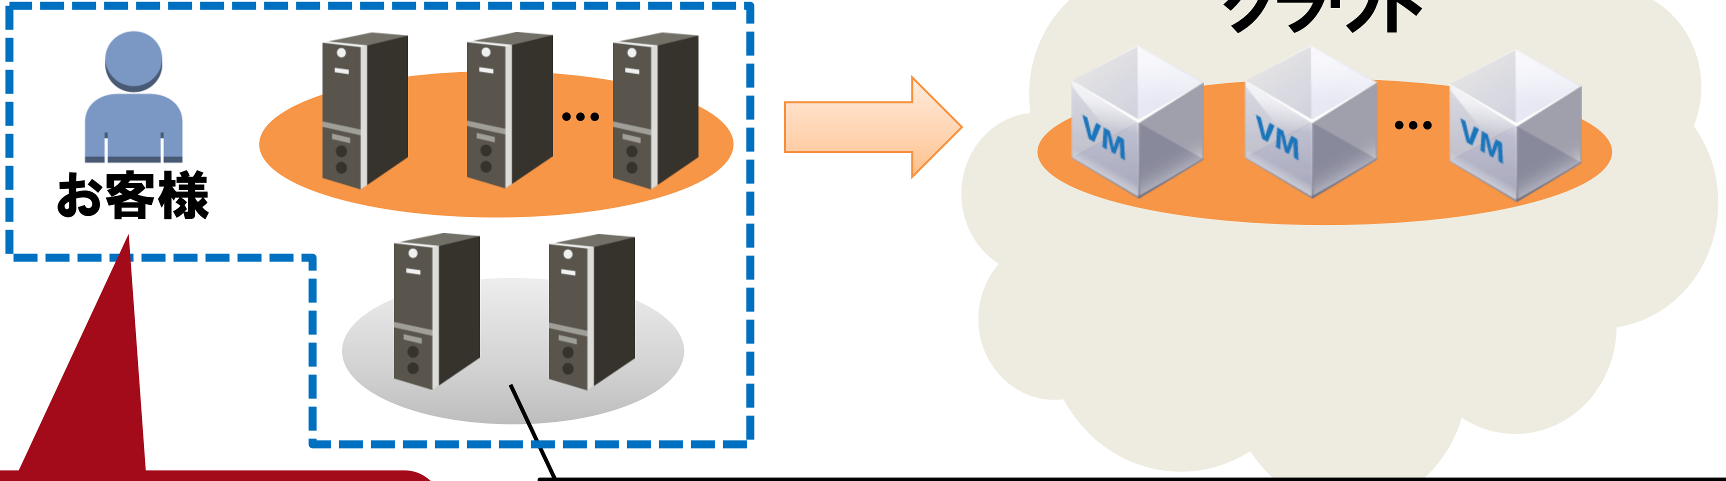

二つの管理を一本化したい

仮想マシン上では運用に適さない業務
（CPU負荷 or ディスクI/O性能が重視されるワークロードなど）

なぜベアメタルサービスが必要なのか？

■オンプレミス → クラウドの普及

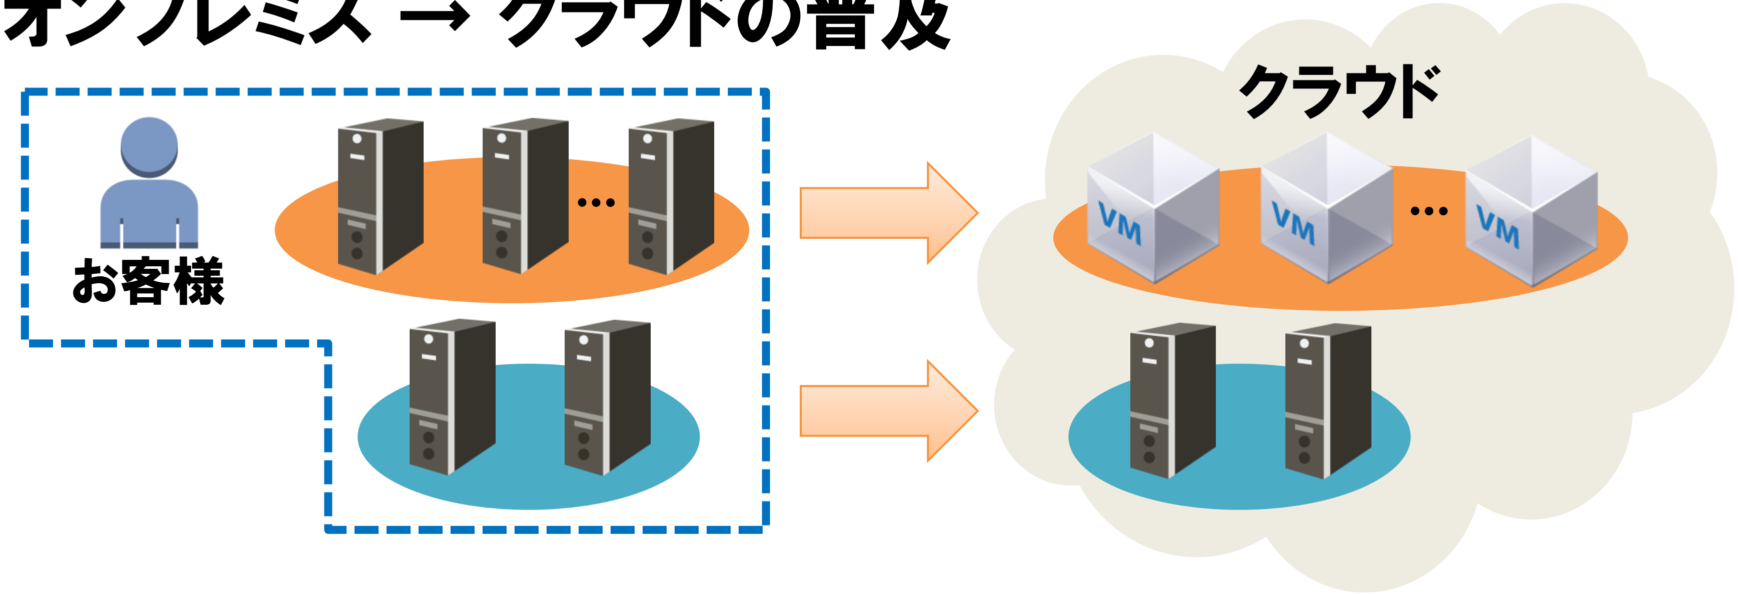

管理コストの削減・クラウドが持つ便利な機能の享受

【補足】利用者の関心

公式の User Surveyより［1］

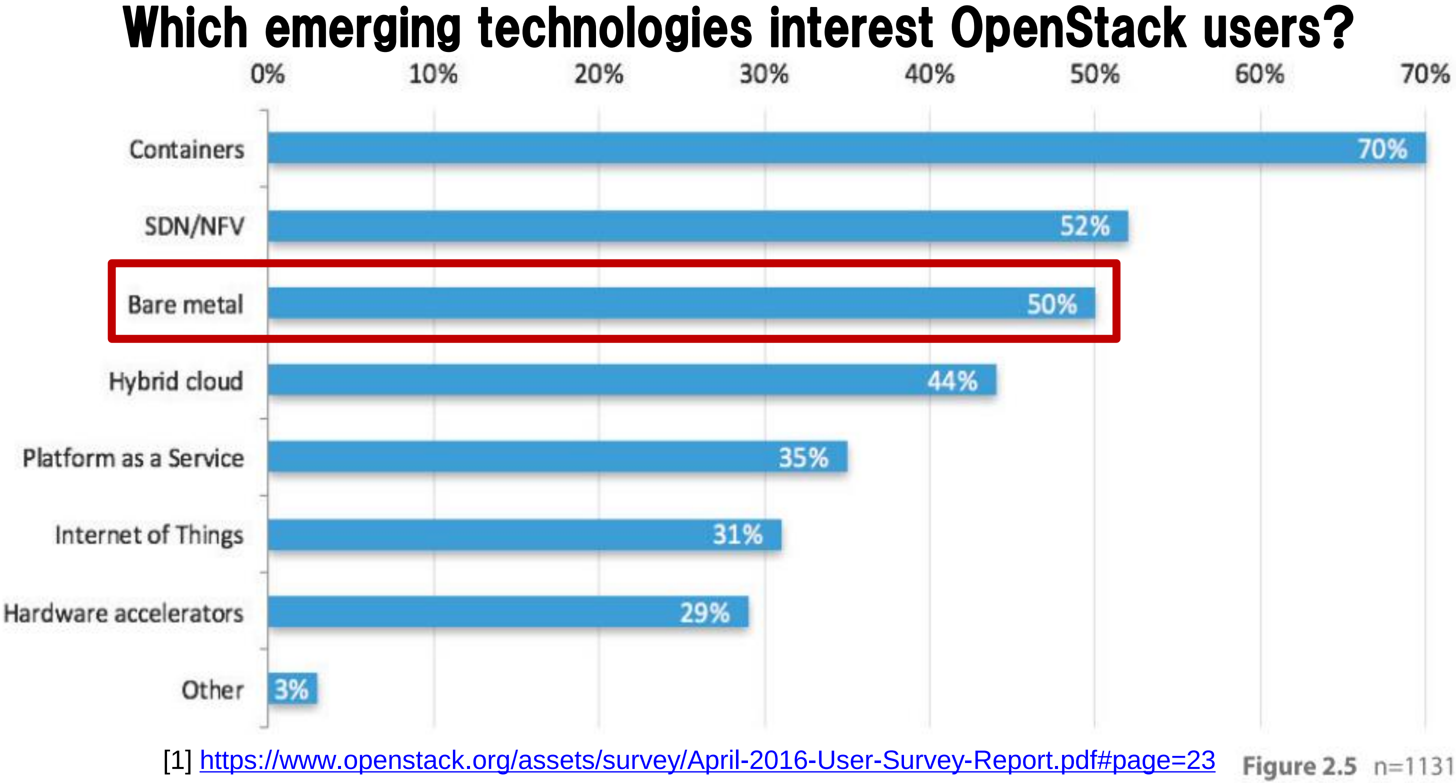

[1] https://www.openstack.org/assets/survey/April-2016-User-Survey-Report.pdf#page=23

目指すべき世界に向けて

我々が目指すべき世界

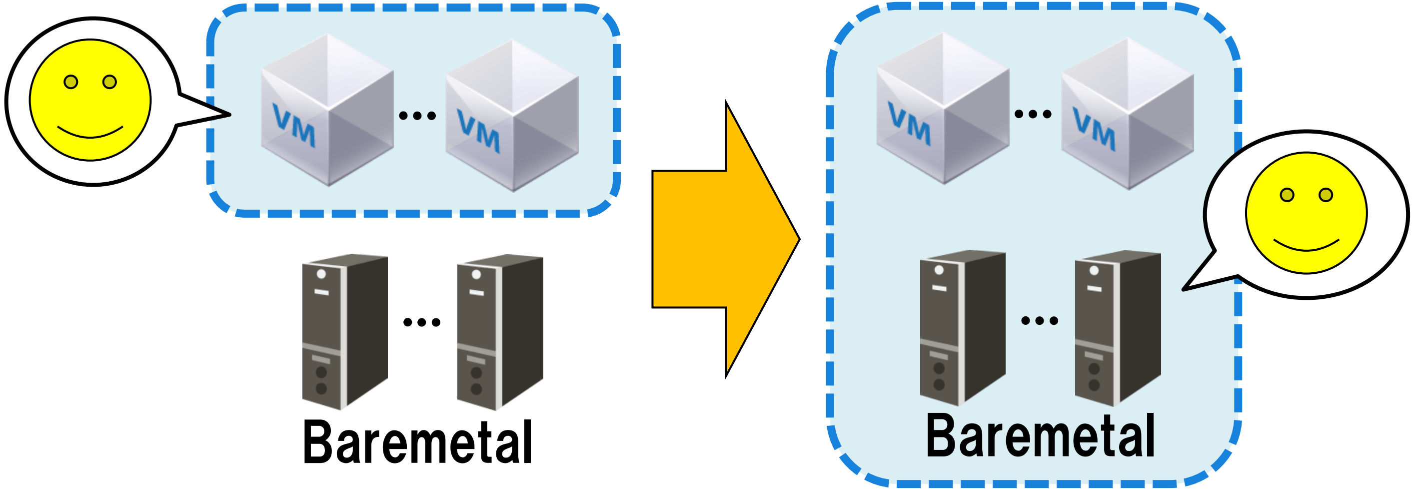

マルチテナント

SecurityGroup

仮想Volume

Graceful Shutdown

Console

仮想/クラウドから出た技術をベアメタルでも実現する

開発内容紹介

☑ 導入フェーズ（配備）
- マルチテナント、LAG（冗長化）
- SAN対応（Cinder連携）

□ 正常時運用フェーズ

□ 異常時運用フェーズ

マルチテナント対応状況

【Mitaka時点】

仮想（VM）

- テナントごとに分離された任意のネットワーク上に配備可能
- 分離方式として以下：

VLAN, VXLAN, gre, geneve

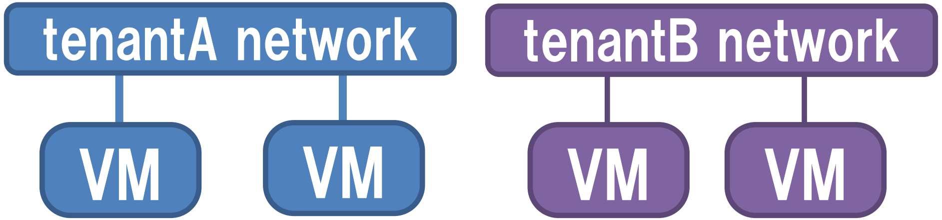

物理（BM）

- Controllerと同じネットワーク上にのみ配備可能
- Flatネットワークのみのサポート（テナント間分離なし）

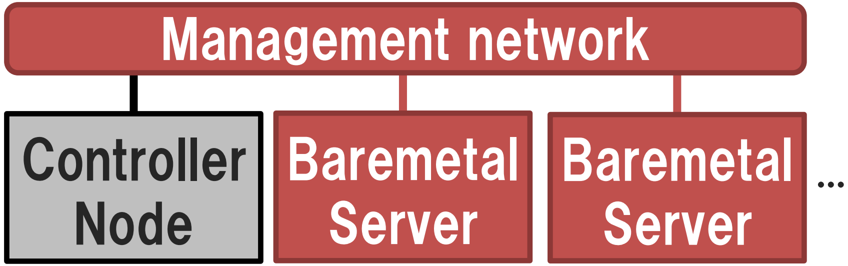

開発内容: マルチテナント対応

仮想（VM）

- Open vSwitch上にVLAN設定

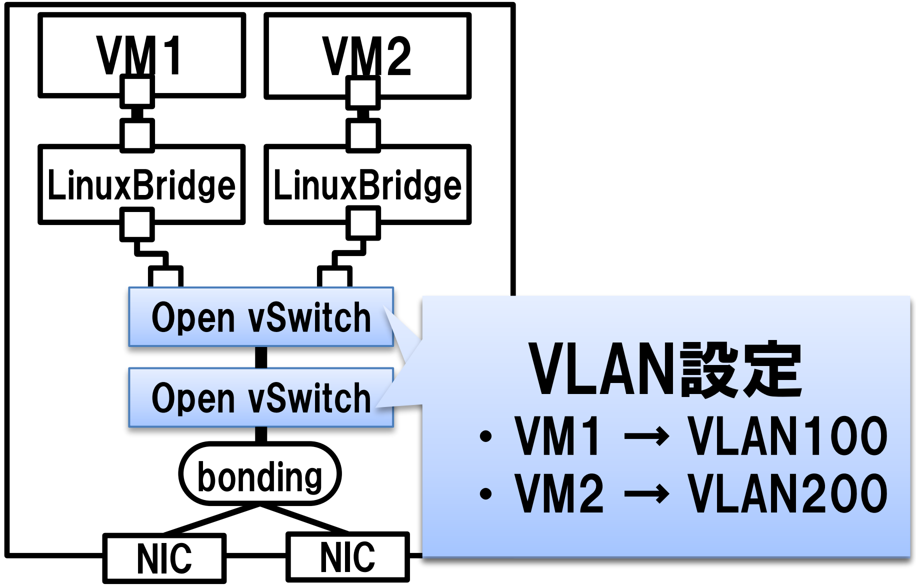

VLAN設定

- VM1 → VLAN100
- VM2 → VLAN200

物理（BM）

- 物理スイッチの特定のポートに対して VLAN (Untagged) 設定
- NeutronのML2プラグインを利用
- ポイント：ネットワークフリップ

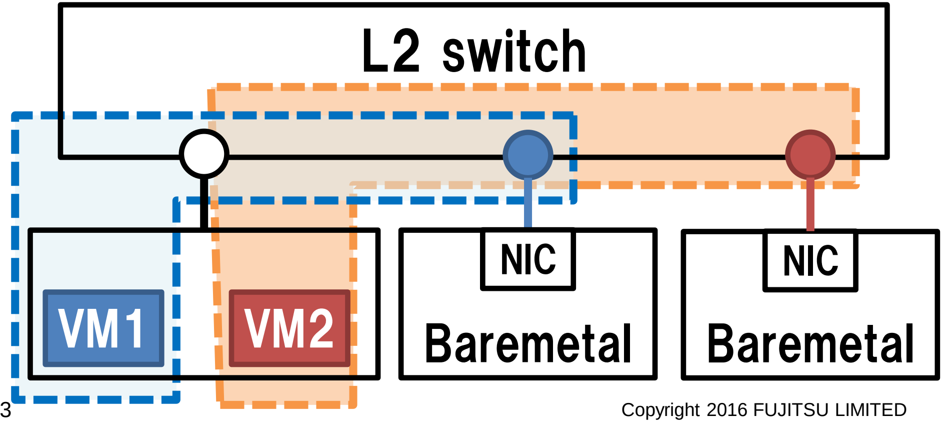

ネットワークフリップ (1/3)

配備中にネットワークを切り替える:

1. 管理ネットワークへ接続
2. 接続解除
3. テナントネットワークへ接続

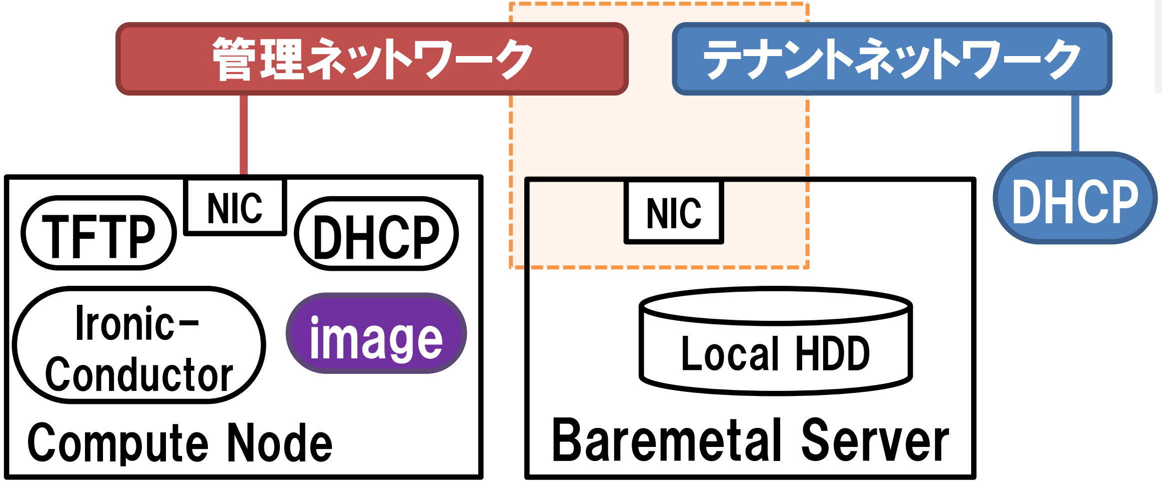

管理ネットワーク上にあるもの

- TFTPサーバ
- ironic-conductor
- Deploy image(配備用)
- Boot image(お客様用)

配備中に一旦接続する必要がある

ネットワークフリップ (1/3)

配備中にネットワークを切り替える:

1. 管理ネットワークへ接続
2. 接続解除
3. テナントネットワークへ接続

管理ネットワーク上にあるもの

- TFTPサーバ
- ironic-conductor
- Deploy image(配備用)
- Boot image(お客様用)

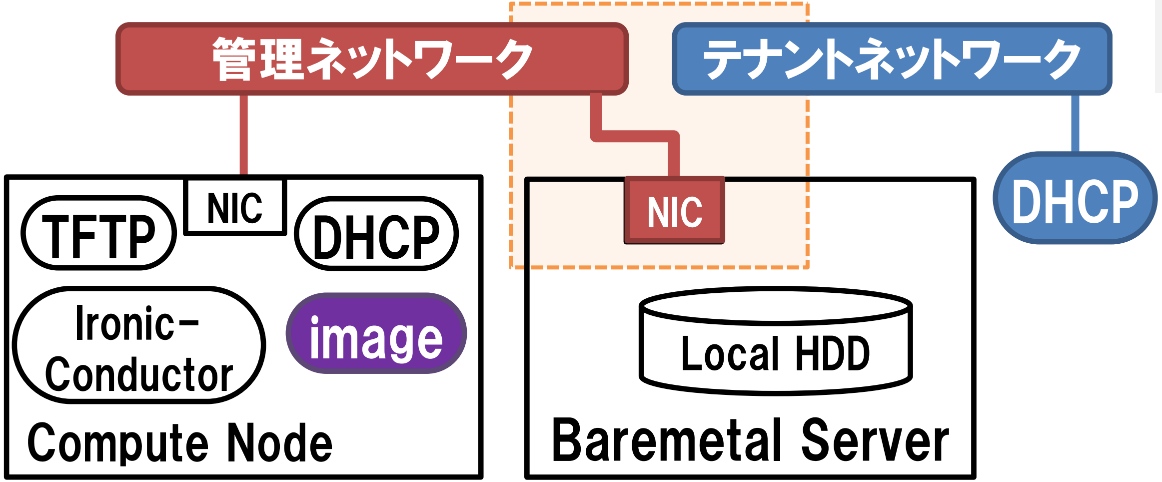

配備中に一旦接続する必要がある

ネットワークフリップ(1/3)

配備中にネットワークを切り替える:

1. 管理ネットワークへ接続
2. 接続解除
3. テナントネットワークへ接続

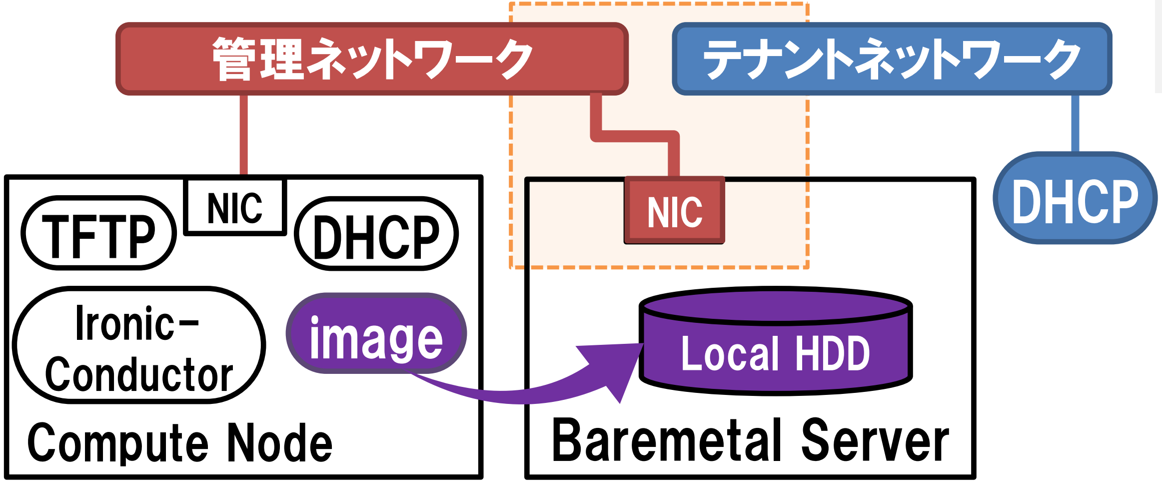

管理ネットワーク上にあるもの

- TFTPサーバ
- ironic-conductor
- Deploy image(配備用)
- Boot image(お客様用)

配備中に一旦接続する必要がある

ネットワークフリップ (2/3)

配備中にネットワークを切り替える:

1. 管理ネットワークへ接続
2. 接続解除
3. テナントネットワークへ接続

管理ネットワーク上にあるもの

- TFTPサーバ
- ironic-conductor
- Deploy image(配備用)
- Boot image(お客様用)

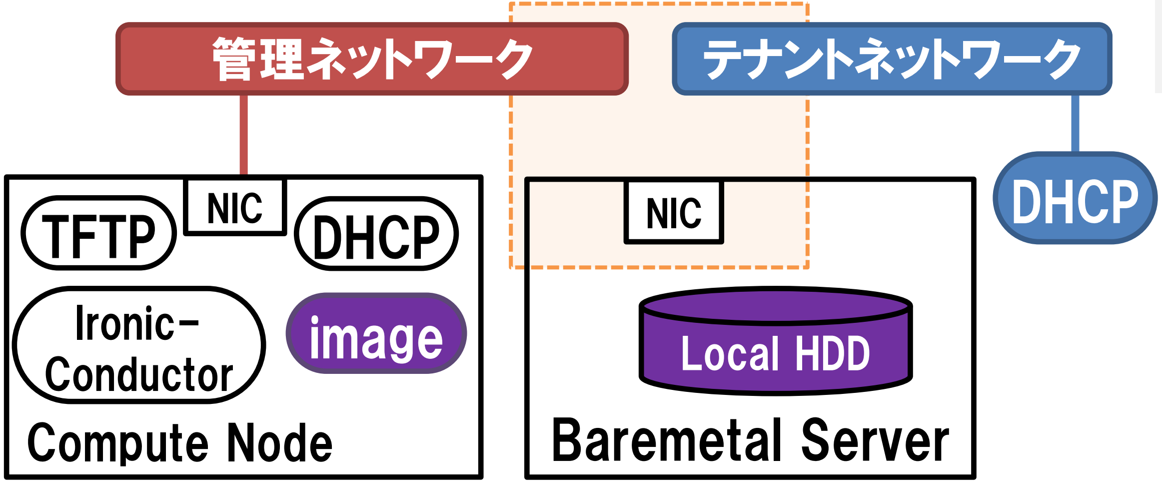

配備中に一旦接続する必要がある

ネットワークフリップ(3/3)

配備中にネットワークを切り替える:

1. 管理ネットワークへ接続
2. 接続解除
3. テナントネットワークへ接続

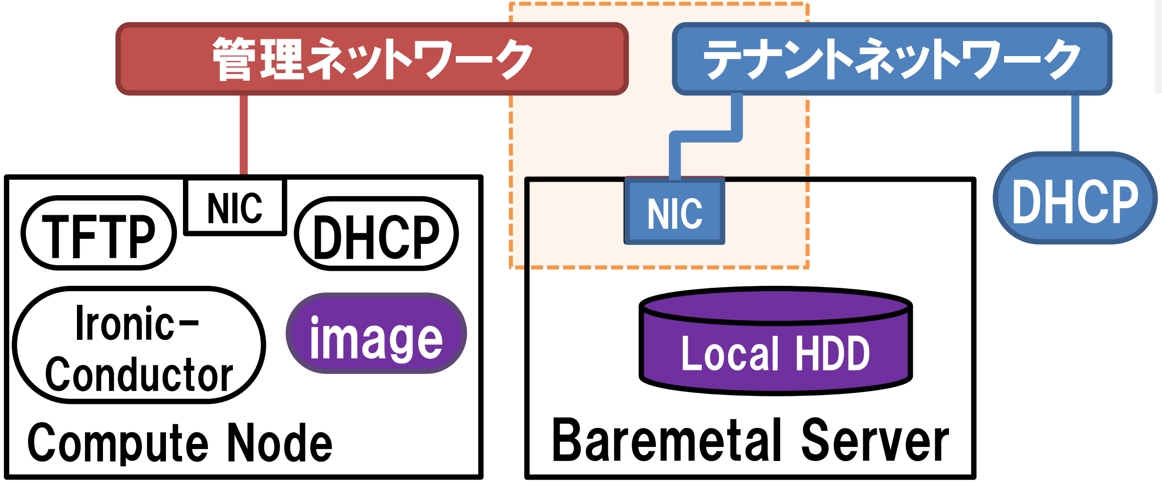

管理ネットワーク上にあるもの

- TFTPサーバ
- ironic-conductor
- Deploy image(配備用)
- Boot image(お客様用)

配備中に一旦接続する必要がある

開発内容：ネットワーク経路冗長化（LAG）

仮想（VM）

- ComputeNodeの物理NICにて実現

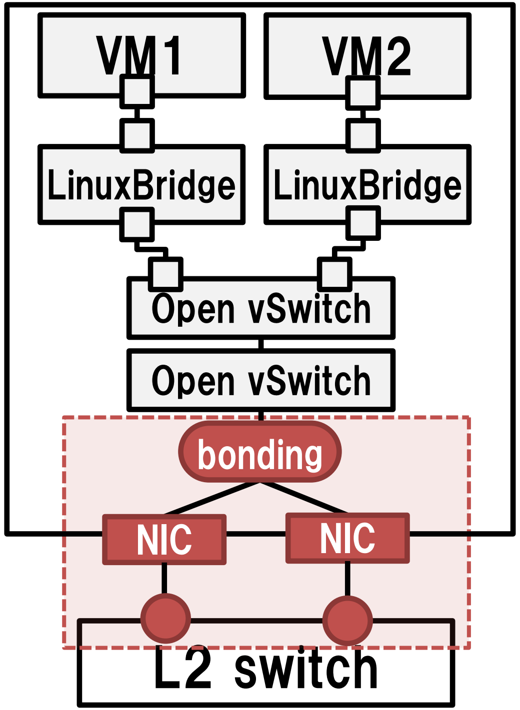

物理（BM）

- 物理スイッチ上でLAGを設定
- ベアメタルのOS上でNICのbonding
  - Nova configdrive を利用

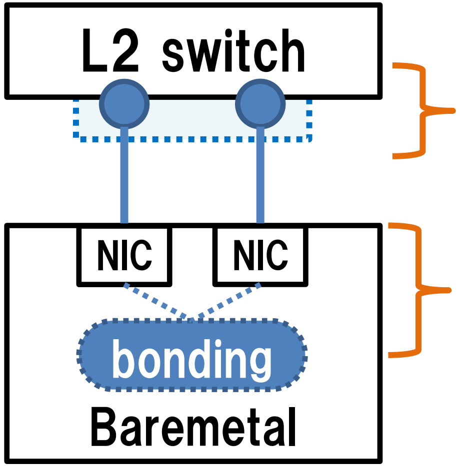

LAG（Link Aggregation）

Config driveから情報を取得してbonding

開発内容：SAN対応（Cinder連携）

仮想（VM）

- ホストがボリュームに直接接続
- VMはボリュームの実体を意識不要

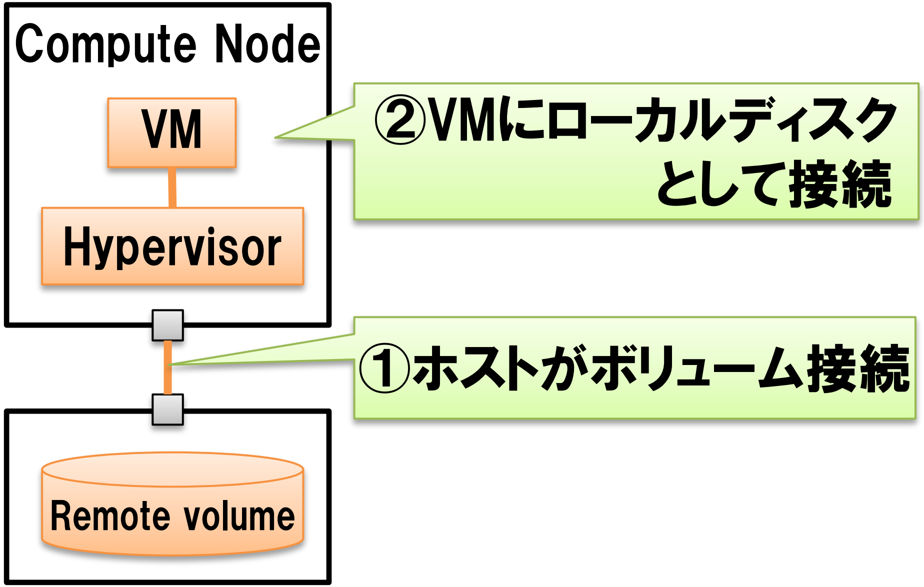

②VMにローカルディスクとして接続

①ホストがボリューム接続

物理（BM）

- ベアメタルサーバをボリュームに直接接続

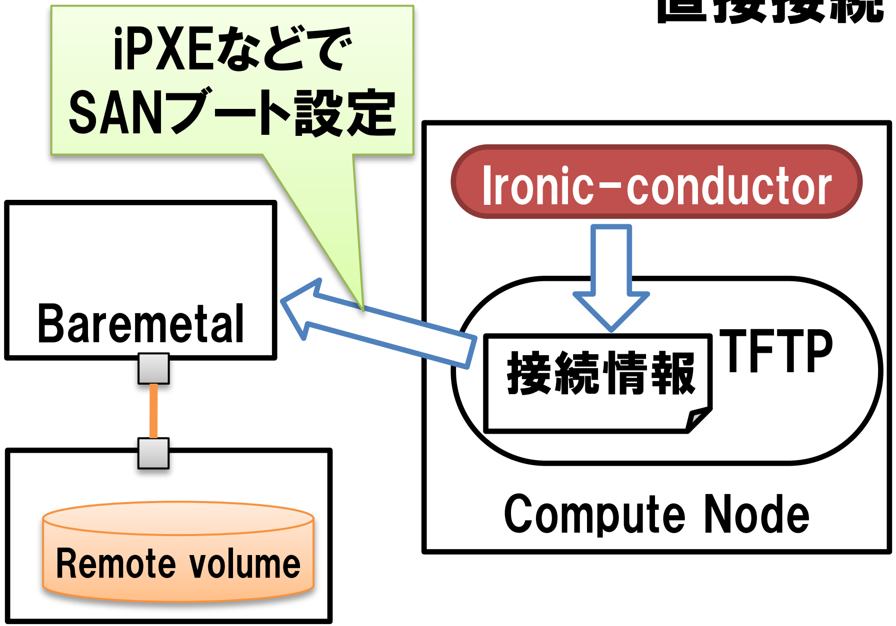

iPXEなどで SANブート設定

Cinder連携の課題

■ストレージのマルチテナント対応

各テナント間のデータが参照できないように

ネットワーク、ストレージ装置での分離が必要

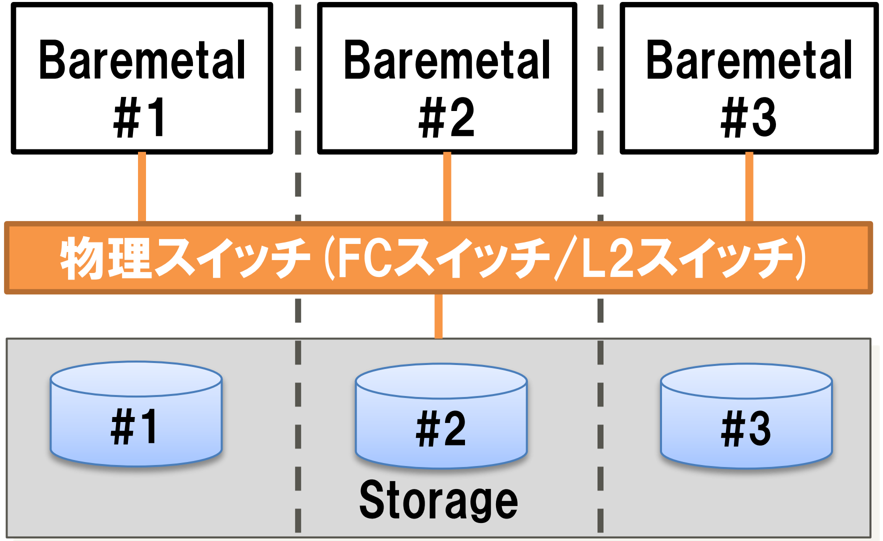

開発内容紹介

□ 導入フェーズ（配備）

☑ 正常時運用フェーズ

- SecurityGroup適用
- 停止（シャットダウン）

□ 異常時運用フェーズ

SecurityGroupとは

- フラットなネットワーク間でも適用可能なパケットフィルタリング機能
- 実体は iptables

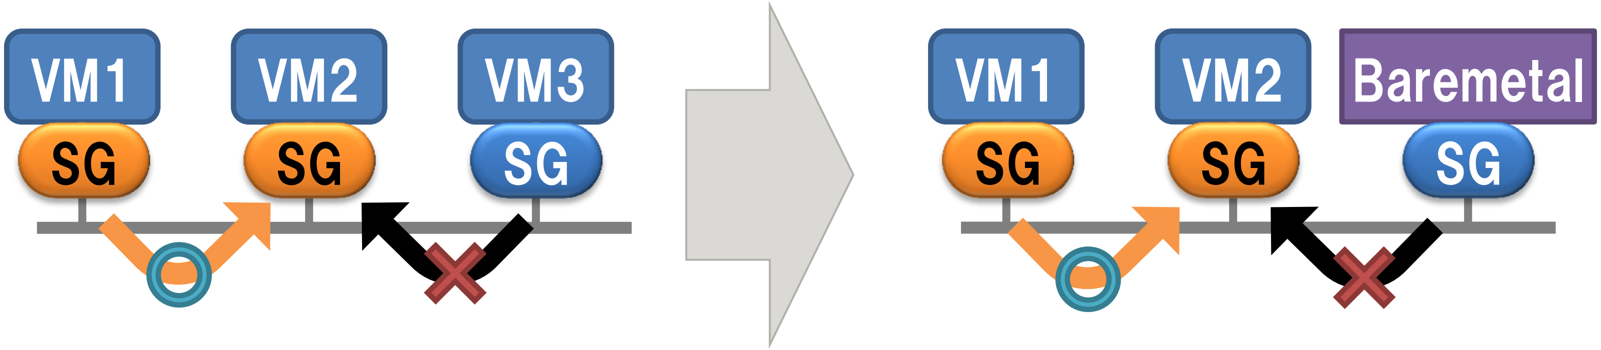

開発内容：SecurityGroup適用

仮想（VM）

- Linux bridge上にiptablesを設定することでSecurityGroupを実現

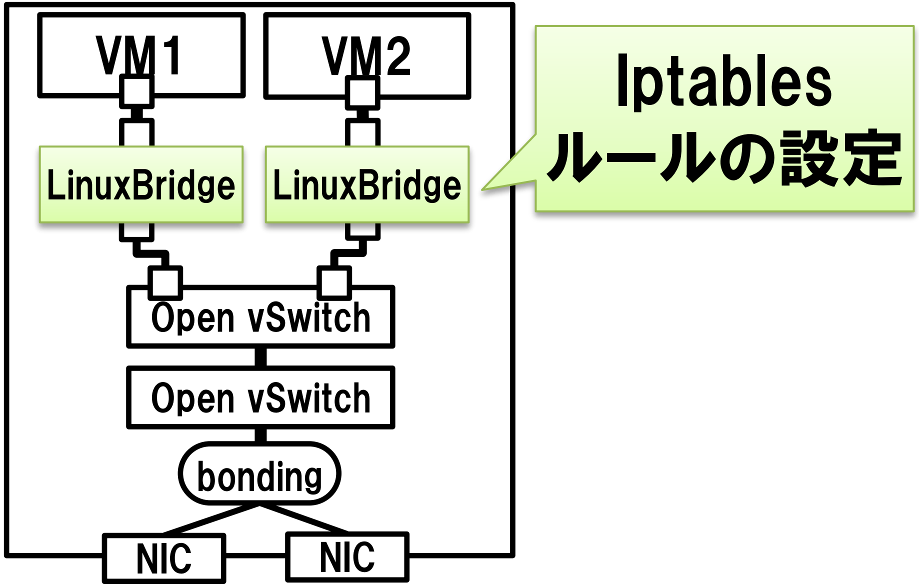

Iptables
ルールの設定

物理（BM）

- Neutronプラグインを拡張して物理スイッチ上のACL（Access Control List）を制御

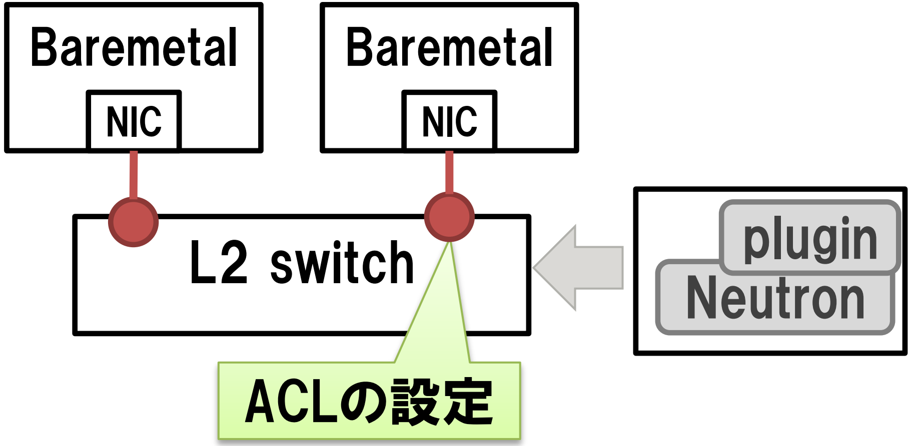

ACLの設定

開発内容: Graceful shutdown

仮想(VM)

- HypervisorがACPIを送信する

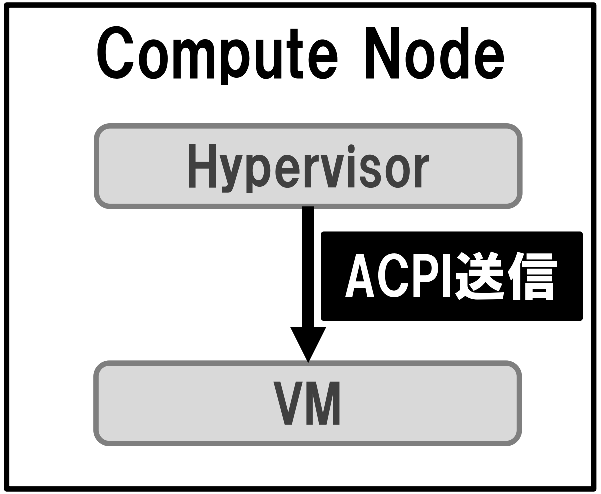

Compute Node

Hypervisor

ACPI送信

VM

物理(BM)

- Ironic-CondurcorがipmitooI経由でBMCからACPIを送信させる

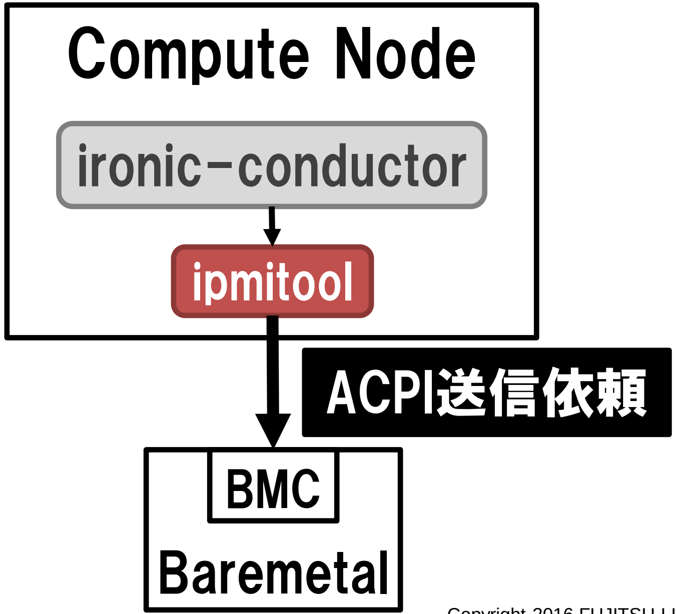

Compute Node

ironic-conductor

ipmitool

ACPI送信依頼

BMC

Baremetal

開発内容紹介

□ 導入フェーズ（配備）

□ 正常時運用フェーズ

☑ **異常時運用フェーズ**

- カーネルダンプ採取（NMI）
- コンソール接続

開発内容: NMI送信

仮想(VM)

- HypervisorがNMIを送信する

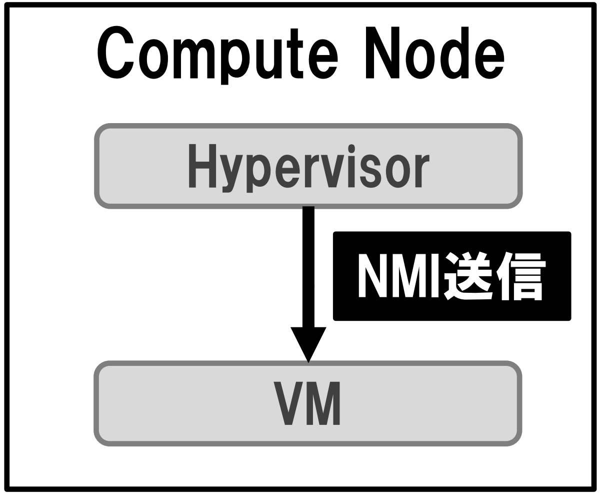
Compute Node

Hypervisor

NMI送信

VM

物理(BM)

- Ironic-Condurcorがipmitool経由でBMCからNMIを送信させる

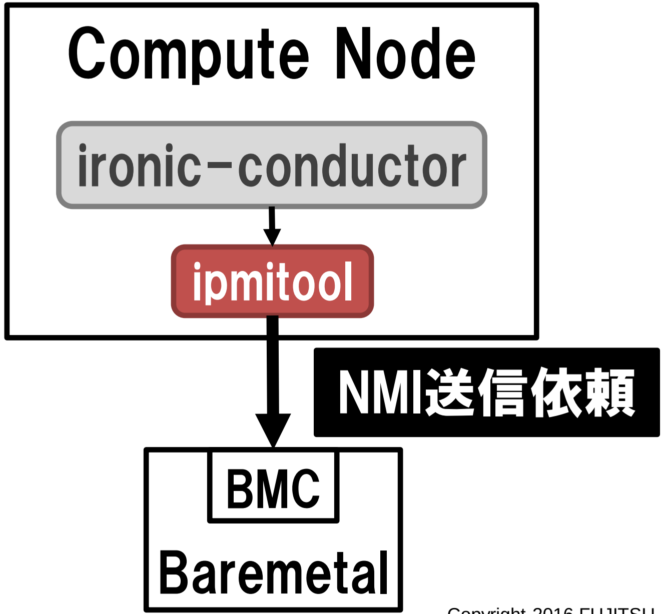
Compute Node

ironic-conductor

ipmitool

NMI送信依頼

BMC

Baremetal

シリアルコンソール

- OSブート時の異常や、ネットワーク異常時の調査手段としてシリアルコンソールアクセスが必要

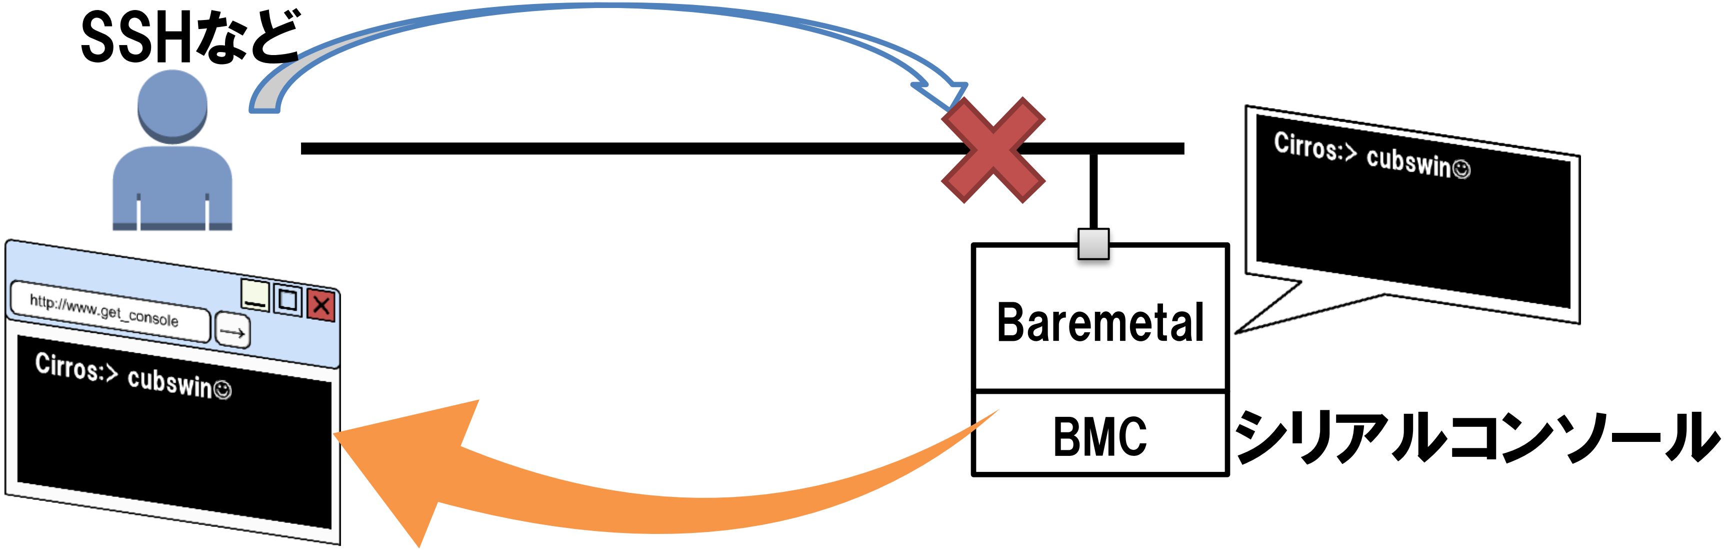

```
Cirros:> cubswin☺
```

```
Cirros:> cubswin☺
```

開発内容: シリアルコンソール対応

仮想（VM）

- Nova-serialproxyがHypervisor側の待ち受けポートにプロキシ

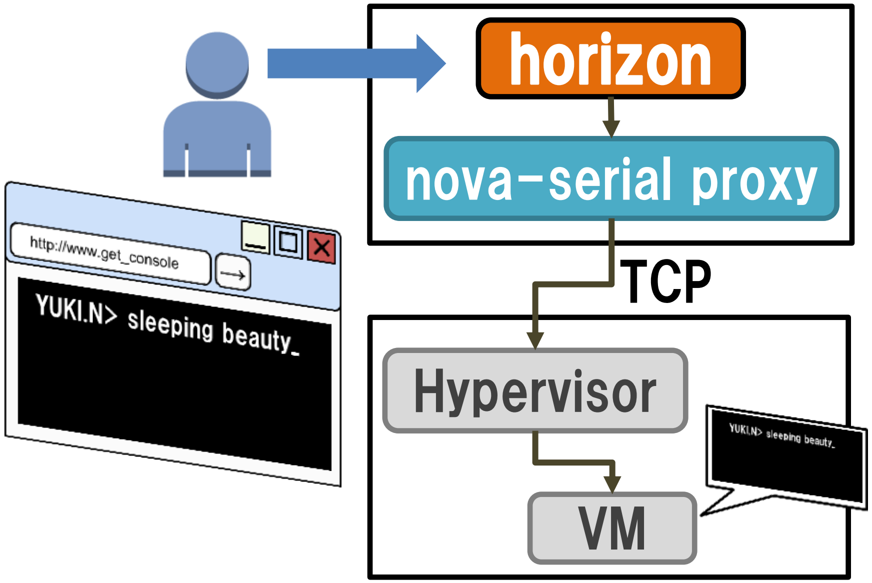

物理（BM）

- SOCATを使ってNova-serialproxyに対応

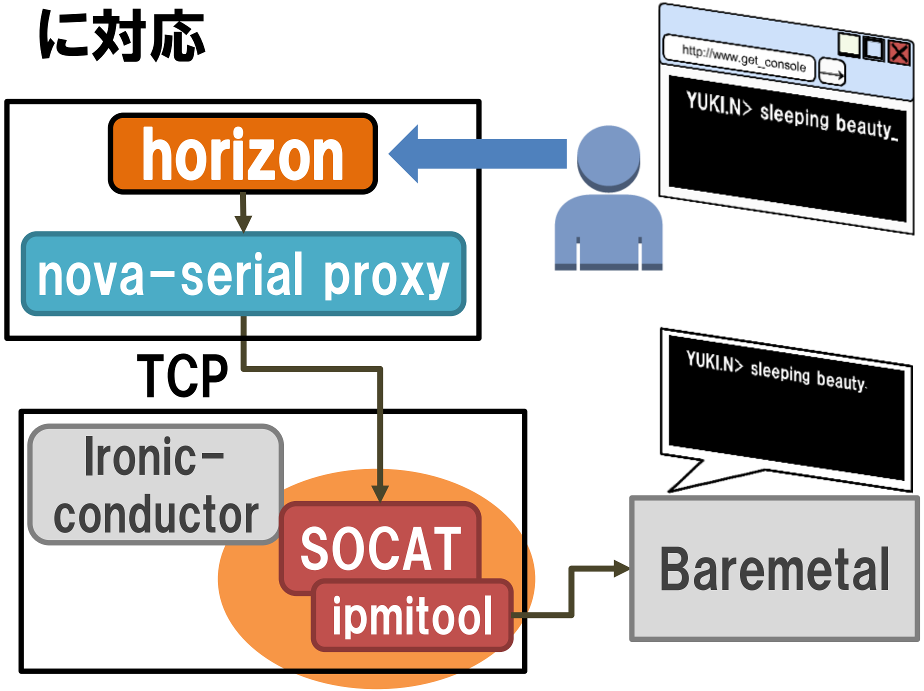

FUJITSU

shaping tomorrow with you