



Openstack 導入事例

ヤフー株式会社

システム統括本部基盤システム開発本部

インフラ技術1部リーダー 伊藤 拓矢

2014年2月14日(金)

- ・ 自己紹介
- ・ OpenStack導入に至る経緯、その理由
- ・ 導入システム構成
- ・ OpenStackを選択した事で困った事/苦労した事
- ・ Openstackを採用する上での注意点
- ・ Openstackでの悩み事、望む事
- ・ 今後について



自己紹介

- ヤフー株式会社（2008年新卒入社）

入社以来インフラ、主にネットワークを担当

2010年から IaaS開発に片足を突っ込む

2013年には IaaS開発に両足を突っ込む

- 現在の業務内容

検証、設計、開発、運用、障害対応、部外交渉、予算管理、
教育、物理から仮想までなんでも



OpenStack導入に至る経緯

- ・ 2008、2009年ころ

VMの利用はこの頃から開始

VMは次Qに利用する数をサービス担当者が申請

申請数に応じて予算化し物理サーバを取得

CLI管理ツールからVMを管理

VMの提供まで3か月ほど掛かる

開発環境のみ 数百VM程度の運用



OpenStack導入に至る経緯

- ・ 2010、2011年ころ

VMを管理しきれなくなる

WebUIからサービス担当者がVMを作成できるシステムの
開発着手

CLI管理ツールをWebでwrapした感じの実装

物理サーバと同じインストールプロセスを踏む

仮想用イメージの作成をしなくても済む

開発環境のみ 数千VMの運用

リソースオンデマンドのための環境を達成



OpenStack導入に至る経緯

- ・ 2010、2011年ころ WebUIによる下記の機能
 - リソースを事前取得してVMを作成(申請してリソースを得る)
 - ロードバランサの設定(VIP)
 - GSLBの設定
 - Ciscoスイッチのコンフィグ変更(ACL)
 - Volumeストレージの設定(動的attach、detach)
 - DNSの自動設定と任意の設定
 - リソース情報の提供
 - WAF、IDSからセキュリティ情報の提供
 - 社内システムとの連携(構成管理、アカウント管理)



OpenStack導入に至る経緯

- ・ 2012年

技術的に古くなりパフォーマンスも良くない

APIは独自のため、OSSとの連携が悪い

コンポーネントの依存が強く、VMのbootまで時間がかかる

運用工数が上がり、リソース不足の中、新規開発が出来ない

このままでは人がインフラを意識しなければならない状況が続く
開発環境とプロダクションでの運用 数万VMの運用



OpenStack導入に至る経緯

・ 2013年

Openstack、CloudStackの検証を始める

社内システムとの連携が必須のため、改良し易いOpenstackを選択
ベーシックな機能は問題なく、すぐに導入を決定

旧来の機能の割り切りも行う

APIもサービス担当者は利用可能になり、Jenkinsなどとも連携

夏頃、開発環境で提供を開始

プロダクション環境でも提供を開始

1万VMほどが稼働中

900プロジェクト、4000ユーザ



OpenStackで配信されるコンテンツ

既にこの環境使ってサービスの一部の機能を提供している

ショッピング、ヤフオク、知恵袋、トラベル、不動産、
ブックストア、ゲームなど





OpenStackを選択した理由

- ・ コードを読めば動きが分かる
 - 検証において、事前に仮定が立てやすい
 - よって導入目標、工数分析しやすい
 - さっと見て導入する機能か、見送る機能が判断できる

例えば、havanaのhorizonで使えるようになったリサイズ、マイグレーション
sharedストレージを使わないでマイグレーションさせようとする、
「sshしてディレクトリ作る。rsyncやscpする」

- ・ nova-computeの権限でする
- ・ セキュリティ的な制限を加えたい
- ・ 導入までにはちょっと工数かかる
- ・ sharedストレージの導入を行うモチベーションへ

```
migrate_disk_and_power_off
if not shared_storage:
    utils.execute('ssh', dest, 'mkdir', '-p', inst_base)
-----
def copy_image(src, dest, host=None):
    try:
        execute('rsync', '--sparse', '--compress', '--dry-run', src, dest)
    except processutils.ProcessExecutionError:
        execute('scp', src, dest)
    else:
        execute('rsync', '--sparse', '--compress', src, dest)
```



OpenStackを選択した理由

- ・ 必要な物とバージョンの判断が容易に行える
 - HVのパッケージ構成を決める

例えば、ファイルシステム拡張や、ファイル挿入において

「どんなモジュールが選択されるか」

- ・ guestfsがあれば使う
- ・ guestfsがなければ、diskフォーマットがrawならloopbackマウント
- ・ それ以外ならnbdを使う

```
class VFS(object):
    def instance_for_image(imgfile, imgfmt, partition):
        hasGuestfs = False
        try:
            importutils.import_module("guestfs")
            hasGuestfs = True
        if hasGuestfs:
            return importutils.import_object(
                "nova.virt.disk.vfs.guestfs.VFSGuestFS",
                imgfile, imgfmt, partition)
        else:
            return importutils.import_object(
                "nova.virt.disk.vfs.localfs.VFSLocalFS",
                imgfile, imgfmt, partition)
```





OpenStackを選択した理由

- ・ 開発が活発
 - 多ベンダーが開発に参加していて、アプライアンスなどの選択枠が非常に多い
- ・ 致命的なバグは少ない
 - 検証した上で採用すれば問題ない
- ・ オープンで多くの企業が参加できる
 - OSSの活性化は喜ばしい

Openstack全体を共に盛り上げていきたい企業を募集



導入システム構成

- 利用しているOpenstackのコンポーネント
Keystone, Nova, Neutron, Cinder, Glance, Horizon
- Openstackを動かすために
mysql, qpid, rabbitmq, qemu, kvm, linuxbridge, centos, nginx
- 大きく手を加えた所
config driveによる社内システム情報の挿入(アカウント、構成管理)
(ホスト名、アカウント、公開鍵、IPアドレス、GW、ntp.conf、
resolv.conf、sudoers、group)



導入システム構成

- ・ 構成のポイント

- 安定して稼働できる

- パフォーマンスが出る(CPU, IO, Network)

- 内部統制を実現してしっかり守る仕組み

- 誰がいつ作成したのか、作成後、即座にポリシーの強制を開始

- 運用できること(必要なロックは掛ける)


- ・ 使っていない機能

- Openstackに登録した公開鍵の配布機構

- FloatingIP



導入システム構成図 VM net




BIOSの設定変えるの面倒なので、
pxebootでインストールされるHVは
untagなのが良い

OpenstackでVMにtagを付けるのは
容易なのでVMはtagを付ける

NATを使用しない flatなnetwork構成
ゲートウェイはHWアプライアンスに



導入システム構成図 Volume



Volumeの提供はToRSWから
枝分かれしたネットワークで行う

1G時代はToRを2つ置き、物理配線を分けていた
ので昔の名残という側面も



導入システム構成 config

コンポーネント全てに言える事として、sqlalchemyまわりのチューニングは必須

[database]

idle_timeout=480

min_pool_size=10

max_pool_size=40

max_retries=300

retry_interval=2

max_overflow=60

grizzlyのquantum-serverにはこの設定項目が無いので、pythonのライブラリの初期値を直接書き換える必要があった



導入システム構成 config Nova

timeout値の緩和、定期タスクの実行間隔を延ばす

report_interval=60

service_down_time=120

rpc_response_timeout=120

neutron_url_timeout=90

sync_power_state_interval=600

heal_instance_info_cache_interval=120

host_state_interval=300

NeutronやCinderなども同じような項目があるので、延ばします

コンフィグドライブを常に利用する(後述)

force_config_drive=always

RPCに極力負荷を掛けないようにチューニングしていくと、本来の動きが正しく、早く動く



導入システム構成 プロセスの並列化

- APIはnginxを挟んで複数プロセスを立ち上げる



endpointはnginxに向ける
nginxのupstreamとして下の
コントローラの各ポートに
ロードバランスさせる



ctrl1



ctrl2



ctrl3

keystone-1
Listen 5001,35358

keystone-2
Listen 5002,35359

keystone-3
Listen 5003,35360

neutron-sever
Listen 19696

keystone-1
Listen 5001,35358

keystone-2
Listen 5002,35359

keystone-3
Listen 5003,35360

neutron-sever
Listen 19696

keystone-1
Listen 5001,35358

keystone-2
Listen 5002,35359

keystone-3
Listen 5003,35360

neutron-sever
Listen 19696

keystone9つ、neutron3つ

本番の運用は大体こんな感じ

haproxyがリファレンスか



導入システム構成 プロセスの並列化

- nova-scheduler, nova-conductorは増やす



ctrl1



ctrl2



ctrl3

この2つに余裕がないと
VMのbootは遅くなる

nova-conductor01

nova-conductor02

nova-conductor03

nova-conductor04

nova-scheduler01

nova-scheduler02

nova-scheduler03

nova-scheduler04

nova-conductor01

nova-conductor02

nova-conductor03

nova-conductor04

nova-scheduler01

nova-scheduler02

nova-scheduler03

nova-scheduler04

nova-conductor01

nova-conductor02

nova-conductor03

nova-conductor04

nova-scheduler01

nova-scheduler02

nova-scheduler03

nova-scheduler04

ただし、conductorのamqp
に対するセッション数は多
いため、amqpのセッション
数は増設後しばらく見張る



導入システム構成 プロセスの並列化

- ・ 理由として、パフォーマンスの問題が大きい
- ・ シングルプロセス、シングルスレッドで動くためプロセスのCPU使用率が100%に張り付く
- ・ havanaではマルチスレッドで動くものが増えた
- ・ computeノードの増加に合わせて、プロセスを増やすのが良い
- ・ 同じコンフィグで問題ないので増やすのは楽
- ・ mysqldのパフォーマンス測定も忘れずに



- 肝となるシステム

cloud-init と独自のinitスクリプトで拡張まわりの実装

VMのイメージには、ランチャーのみ配置

ランチャーはconfig_driveに付属するスクリプトを実行する


スクリプトは構成管理データを読み込んで、ファイルの配置変更を行う

頻繁に更新が入るために、スクリプトの実体はHVに配置

VM起動時点で既に、構成管理システムと接続された状態になる



導入システム構成 config_drive





Openstackの開発と管理

- ・ 社内のgithubとJenkinsを利用してUpstreamと独自コードのマージ
- ・ Jenkinsによる自動テスト、自動ビルド
- ・ QA環境に持っていて、展開、テスト
- ・ Openstack+LBの動作テストといったアプライアンスとのテストはまだまだ手でやる
- ・ 今のところは構築、運用に工数を取られる状況が続き、仕様変更をここで知る・・・



OpenStackを採用した上で困った事 / 苦労した事

- ・ ロードバランサなど、IaaS用途で使いたい機能面の弱さ、設計の甘さ
- ・ amqpの高い稼働率、起こる不具合原因はほぼここ
- ・ Upstreamを追いかけるのが大変・・・
- ・ 仕様がよく変わりますね



Openstackを採用する上での注意点

- ・ 自由すぎる設計

- 選択枠が多すぎて、何を使うかで悩んでしまう
- 選択枠の中で、組合せを間違えると動かない
- コンポーネント間でコンフィグを合わせなければいけないことも多い

ある程度の設計思想を持った上で、検証を開始すると良い

無邪気にチョイスしてみるのも面白い



Openstackを採用する上での注意点

- ・ リファレンスモデルと実際の採用モデルが結構変わるのは当然
 - なんちゃらstackで、ひとまず試してみる
 - 小規模であれば問題なく動く
 - 大規模はひたすらチューニングとの戦い

設計を決めたら、腹をくくる

DBとログに情報は集まるので、ブレなければ大丈夫





- Openstackクラスタに依存しないHV上のVMの移動
 - openstack-vmexport のようなコマンドで、HV上のVM全てを別の環境に持って行ける(nova, neutron, cinderなどまるまる)
 - openstack-vmimport でそれらのデータをまるまる取り込み



- ・ HVのデータ消失時のVMの復旧
 - 7000台くらいHVが有ると、2か月に1台くらいデータ消失が発生
 - HV復旧後にVMをイメージを入れた直後の状態でユーザに戻してあげたいが、現状は難しい
 - novaのデータベースにはVMが存在しているが、実際のHVには無い状態
 - nova deleteすると、fixed ipが解放されてしまう
 - nova replay-bootのようなもので、nova boot直後の状態を再現したい



Openstackでの悩み事、望む事

- Openstackクラスタ自体のマイグレーション
 - このOpenstackのクラスタ、いつまで運用すれば良いのだろうか
 - リリースに併せて、HWとOSをバージョンアップしたいが、Openstackの自律した動き以外の事をさせるのが難しい
- やはりHVに依存する望みが多いです



Openstackでの悩み事、望む事

- ・ 今回話した内容がベストだと思えない
 - 時間的な制約の中、大規模実装を行ったため、今後ベストな実装を検討していく
- ・ スケールさせた事例が出てこないため、自分たちで試行錯誤した結果が今回の内容
- ・ 幸い複数クラスタが有るので、毎回コンフィグを変えて試す事が多い

ナレッジ共有したい

- Neutronまわりもっと検証
ベンダーAPIとの連携
オーバレイNW(パフォーマンスと管理性の問題解決)
様々なNWレイヤの要求の対応
- Ironi導入
VMの柔軟性や近年のオーバヘッドの極小化を加味しても、物理サーバの利点は大きい。TripleOにも使える
- OSS連携の強化
開発の効率化、テストの自動化、本番環境展開の高速化
良いツールを試していく

- Openstackクラスタを越えてのイメージの共有
 - 開発環境クラスタでsnapshot取って、そのままプロダクション環境クラスタへ イメージを持っていく仕組み
 - 数%のトラフィックだけ試してみたいといったサイエンス用途には良い
- インフラ抽象化の推進
 - 使いたい時に使えるようになった今、大規模環境でエンジニアが、インフラを意識せずともサービスを行える環境作り
 - 開発に集中できる環境を作っていきたい

