

# Statut du cloud, CC-IN2P3

## J1 IN2P3-IRFU

26-29 sept. 2016

## **Les types de cloud au CC-IN2P3**

- R & D
- Production
- HPC
- Hébergés

## **L'infrastructure**

- Déploiement
- Schémas & topologie
- Développement
- Consolidation du monitoring
- Benchmarks & performance
- Réseau et OpenStack Neutron

## **Le futur**

- A court terme
- A long terme

# LES TYPES DE CLOUD AU CC-IN2P3

## Pour qui ?

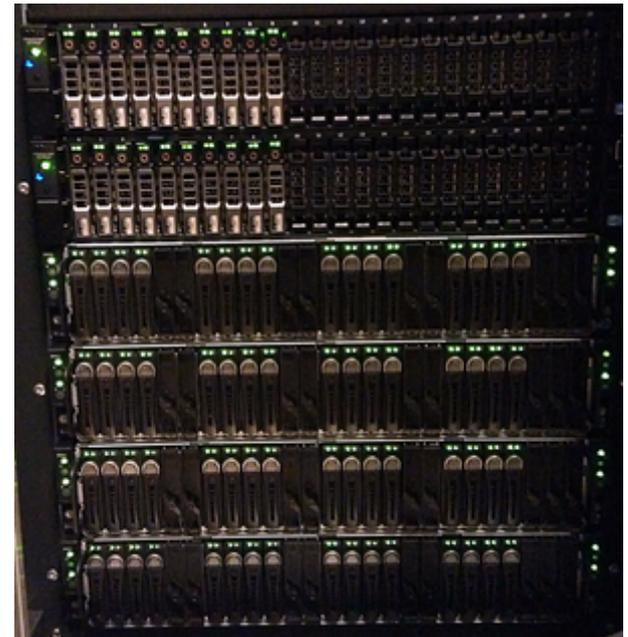
- Les équipes du CC-IN2P3
- Les laboratoires et expériences

## Pour(quoi) ?

- En dehors des services de production
- Tester de nouvelles technologies facilement
- Des ressources en quantité (RAM, CPU, HDD)
- Performance (I/O, CPU et RAM)
- Sauvegarde (snapshot)

## Quelques exemples de services.

- Pre-production (upgrade...)
- Tests de Spark
- Développements TreqS
- CI
- Formations (Puppet, COLOSS...)



## Pour qui ?

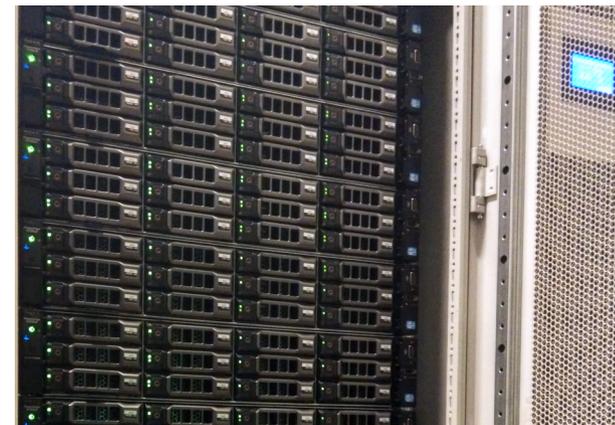
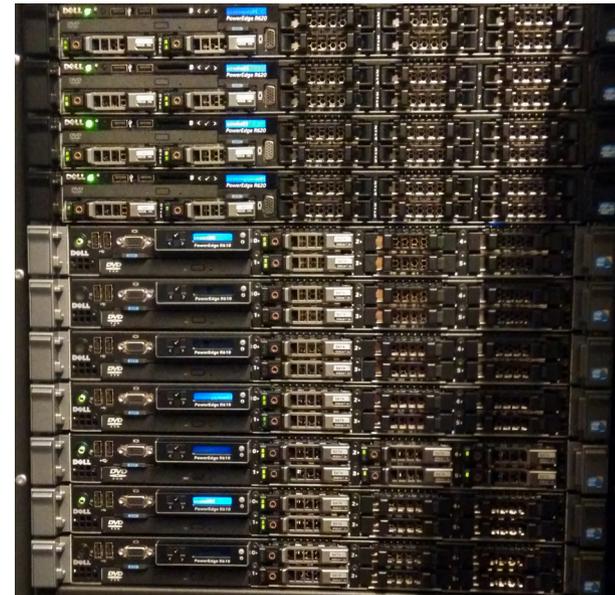
- Les équipes du CC-IN2P3

## Pour(quoi) ?

- Décommissionner VMWare (coût)
- Flexibilité de déploiement (à la demande)
- Performance (I/O, CPU et RAM)
- Haute disponibilité (cluster GPFS, live mig.)

## Quelques exemples de services.

- ElasticSearch
- Kibana
- Grafana
- Kerberos5
- Services Grid
- Puppet Server
- +80 autres



## Les motivations du passage au cloud

- Accéder à des ressources de façon opportuniste
- Des environnements prédéfinis et connus (OS, softwares...)
- Faciliter le déploiement des logiciels
- Une politique de scheduling précise et personnalisable
- Mise en place d'un modèle de computing plus facilement

## Les alternatives au modèle cloud

- Évaluation du scheduler HTCondor et Dirac
- Utilisation des interfaces d'API (EC2/Nova...), Fair Share Scheduling
- Faciliter l'instanciation de nœuds de calcul (Puppet)

## Les expériences utilisant le cloud

- Large Synoptic Survey Telescop (<http://www.lsst.org>)
- Euclid (<http://www.euclid-ec.org/>)
- Atlas (MC simulation)
- Bioaster (<http://www.bioaster.org>)
- ELISA ([www.elisascience.org](http://www.elisascience.org))

## Pour qui ?

- Les utilisateurs des laboratoires de l'IN2P3
- Les expériences

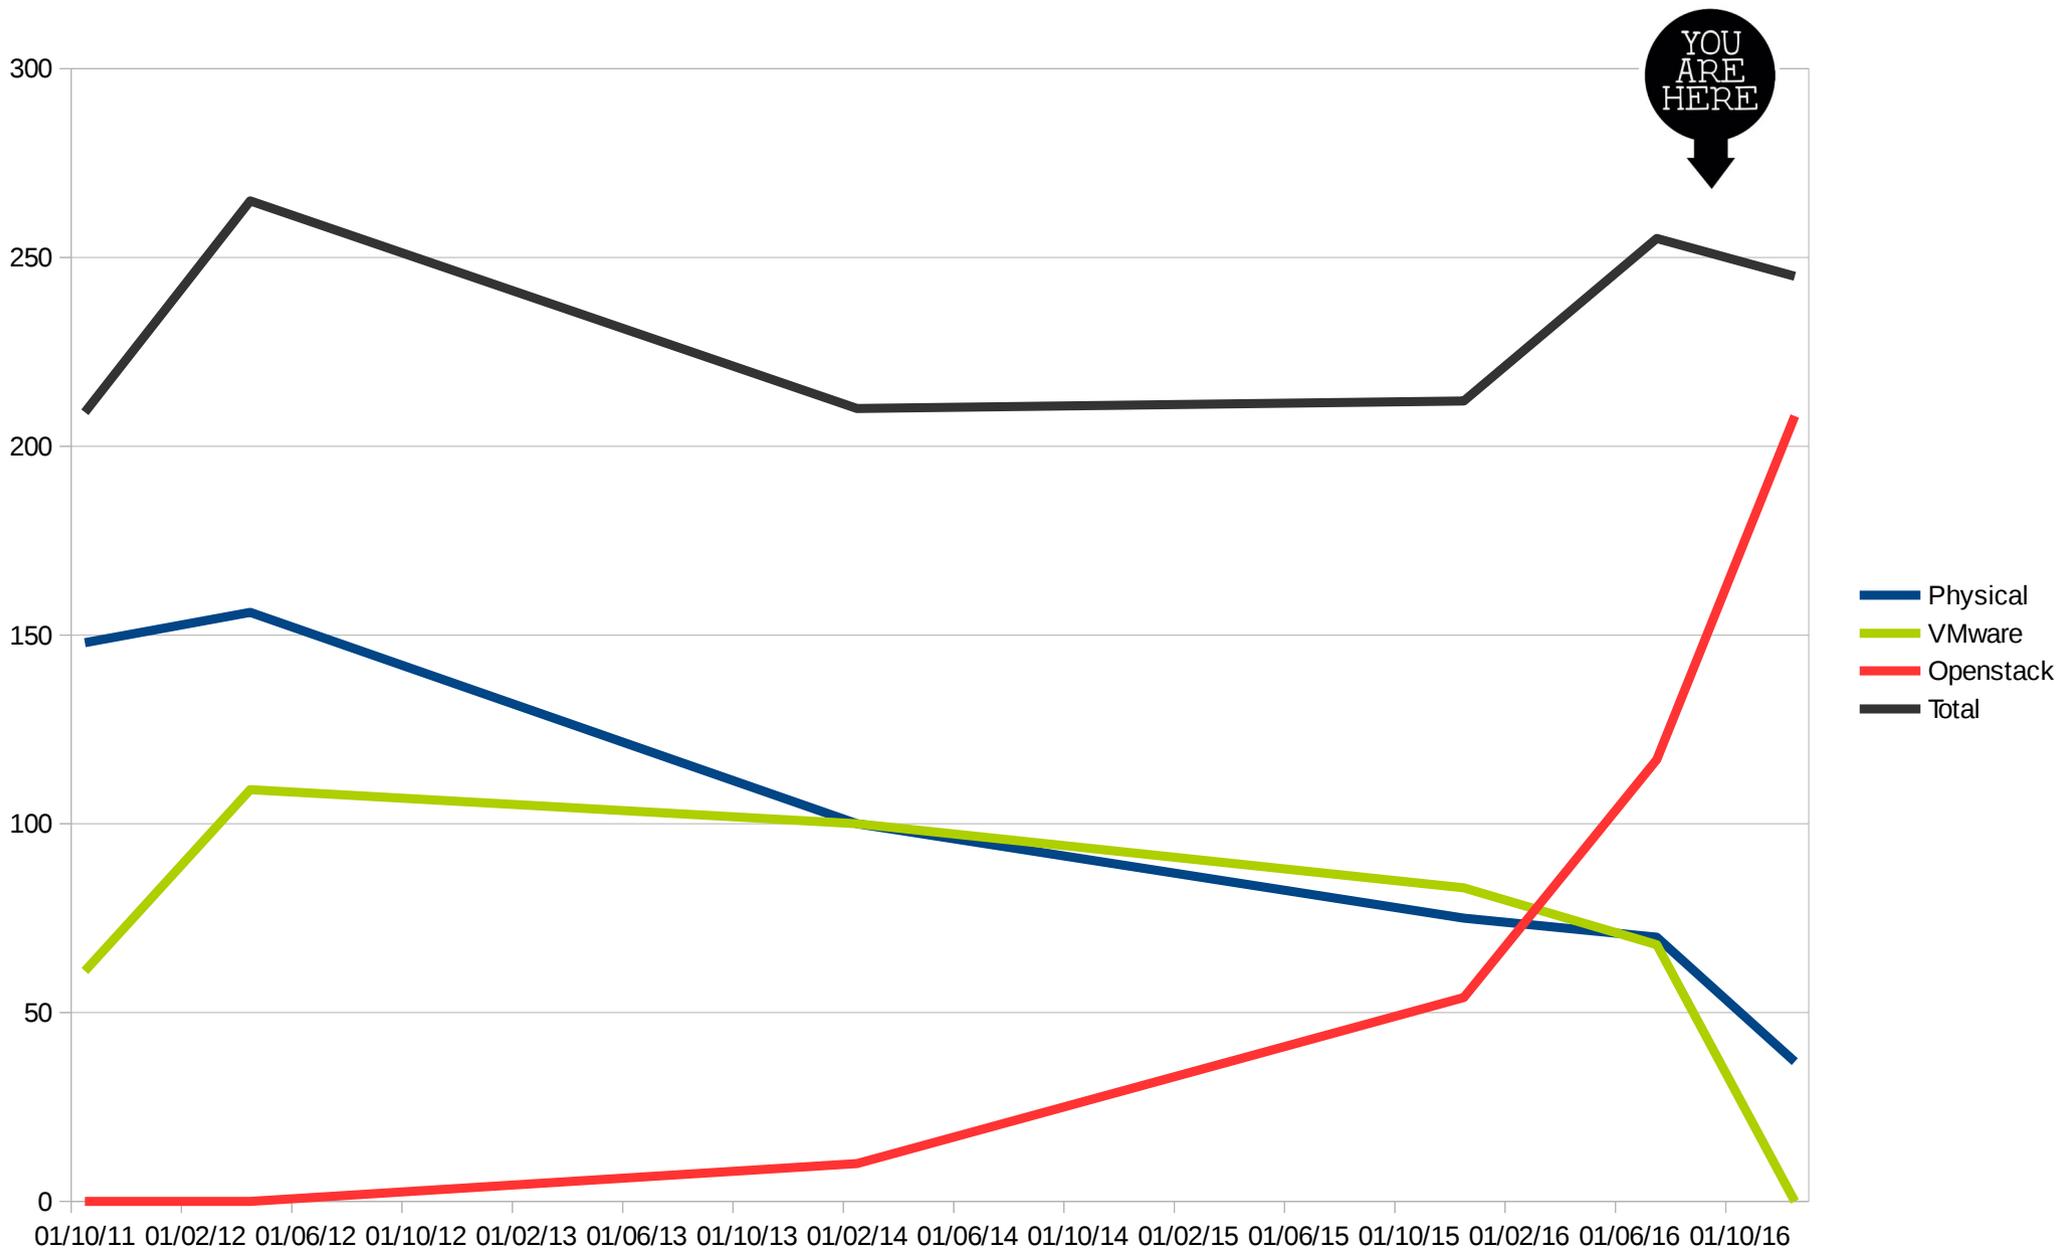
## Pourquoi ?

- Profiter de l'expertise du CC-IN2P3
- Réduction des coûts de maintenance et d'exploitation
- Abstraction de la difficulté technique, démarrer le projet plus vite

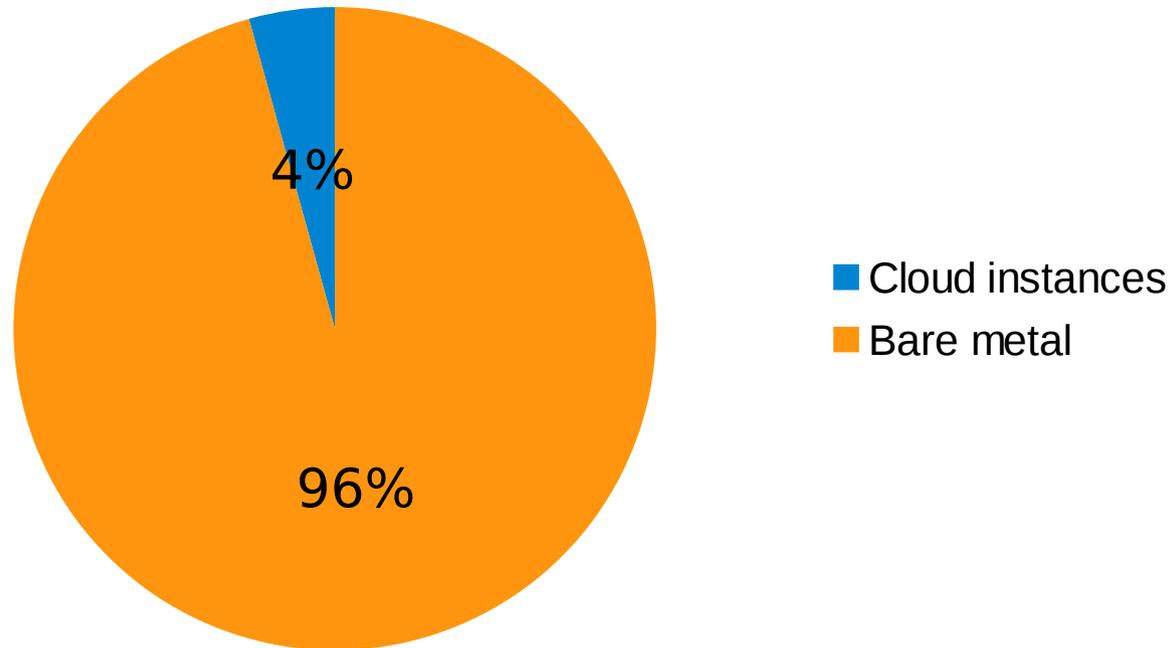
## Quelques projets hébergés

- AMI
- Bioaster
- eTRiKS
- CODEEN (CNES EUCLID)

# Déploiements de services CC



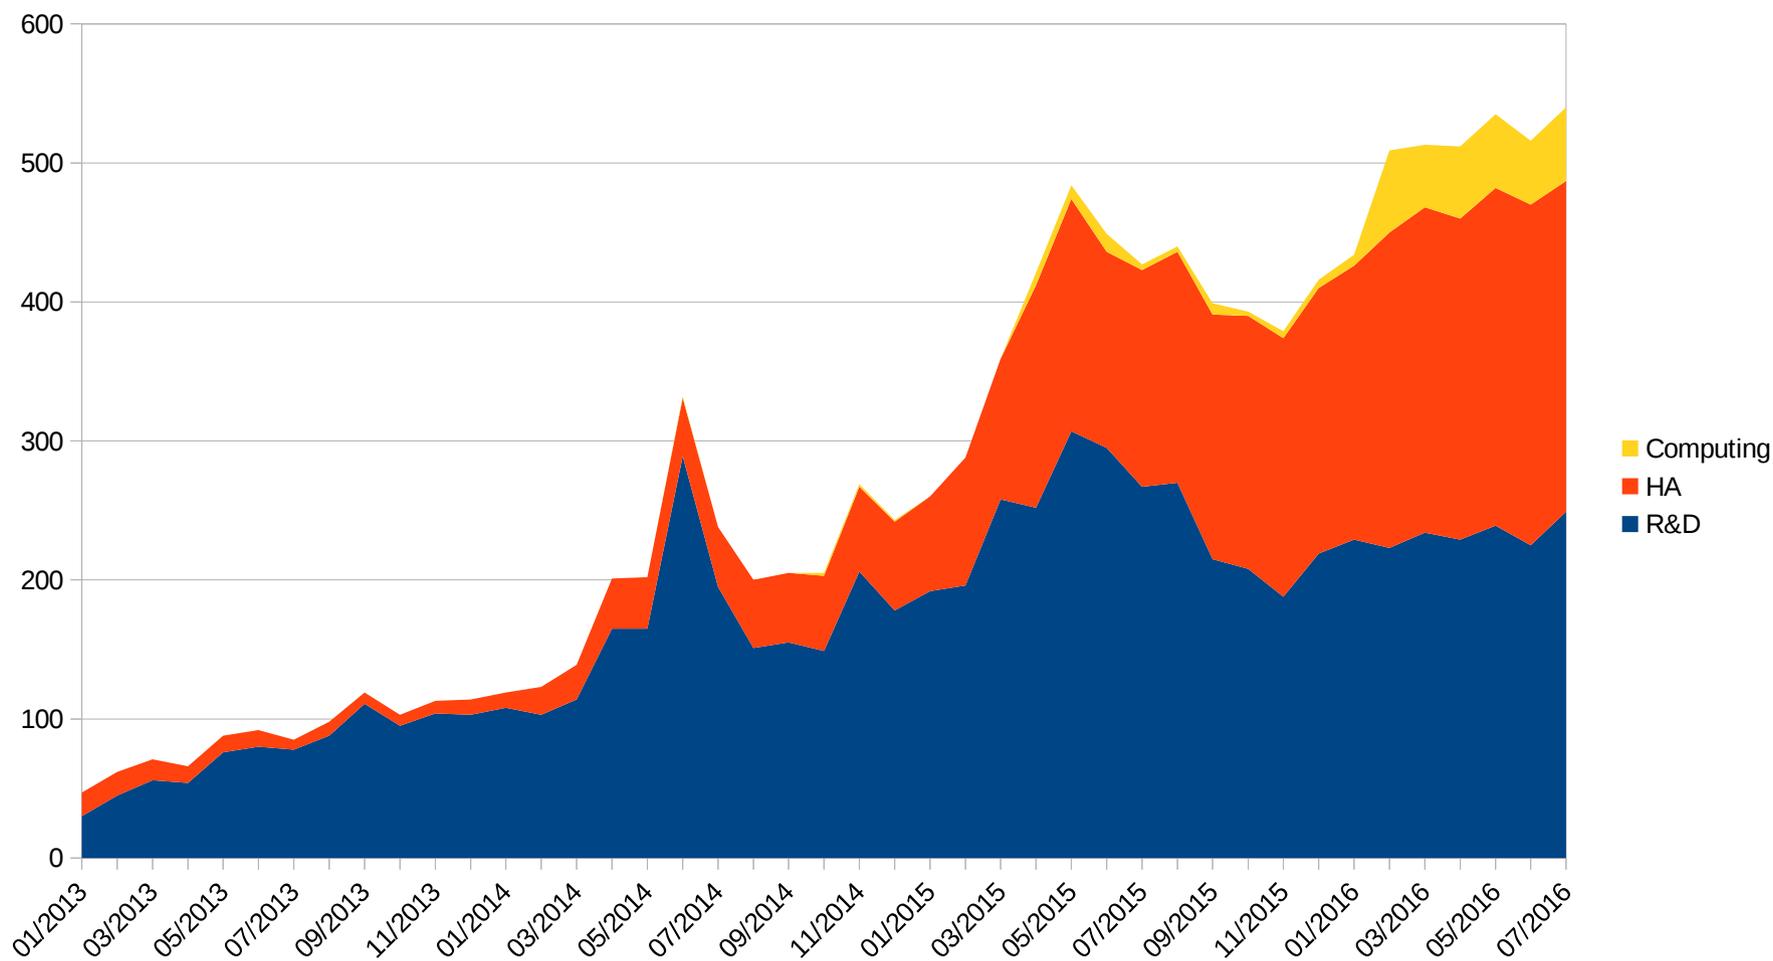
En nombre de machines dédiées aux services CC



## Comparatif HTC

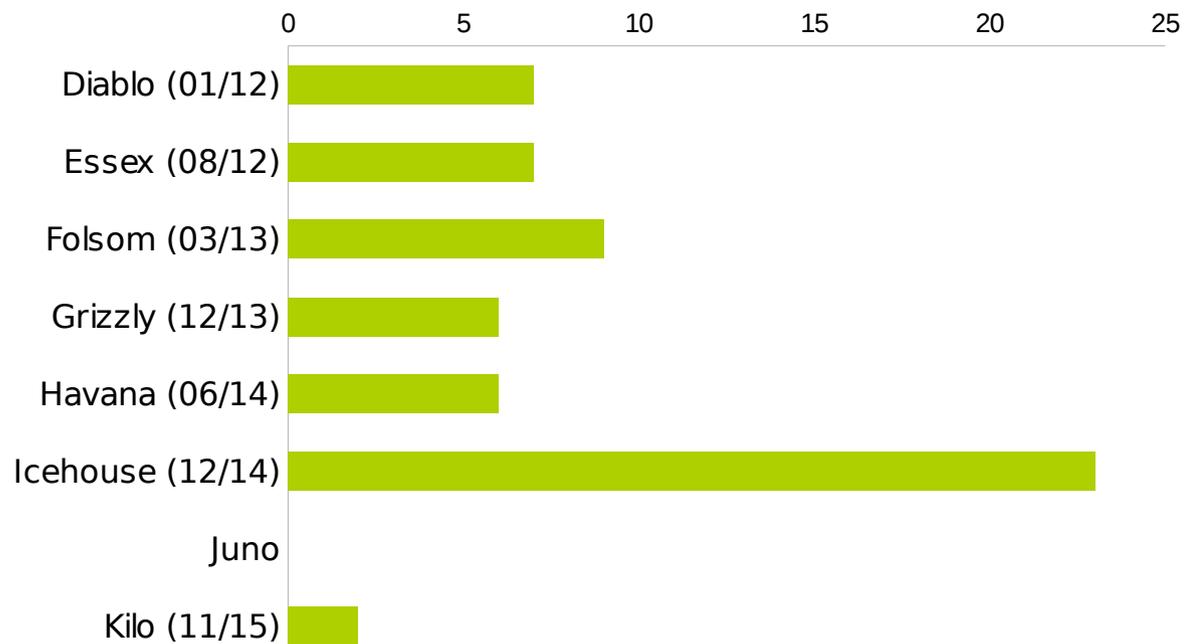
- ~ 1056 cœurs HT en rapport des 25 000 de la ferme HTC (4.2%)
- Passage à 2160 cœurs HT bientôt (gain de 4.4%)

# Statistiques par usage



- En nombre d'instances actives
- projets 50
- utilisateurs 150
- computes 88
- agrégats 16

# INFRASTRUCTURE



En mois d'utilisation

## Composants opérationnels :

Keystone  
Glance  
Nova  
Horizon

Swift  
Rally  
Ceilometer  
Cinder

## Composants en cours :

Heat  
Neutron

## Software

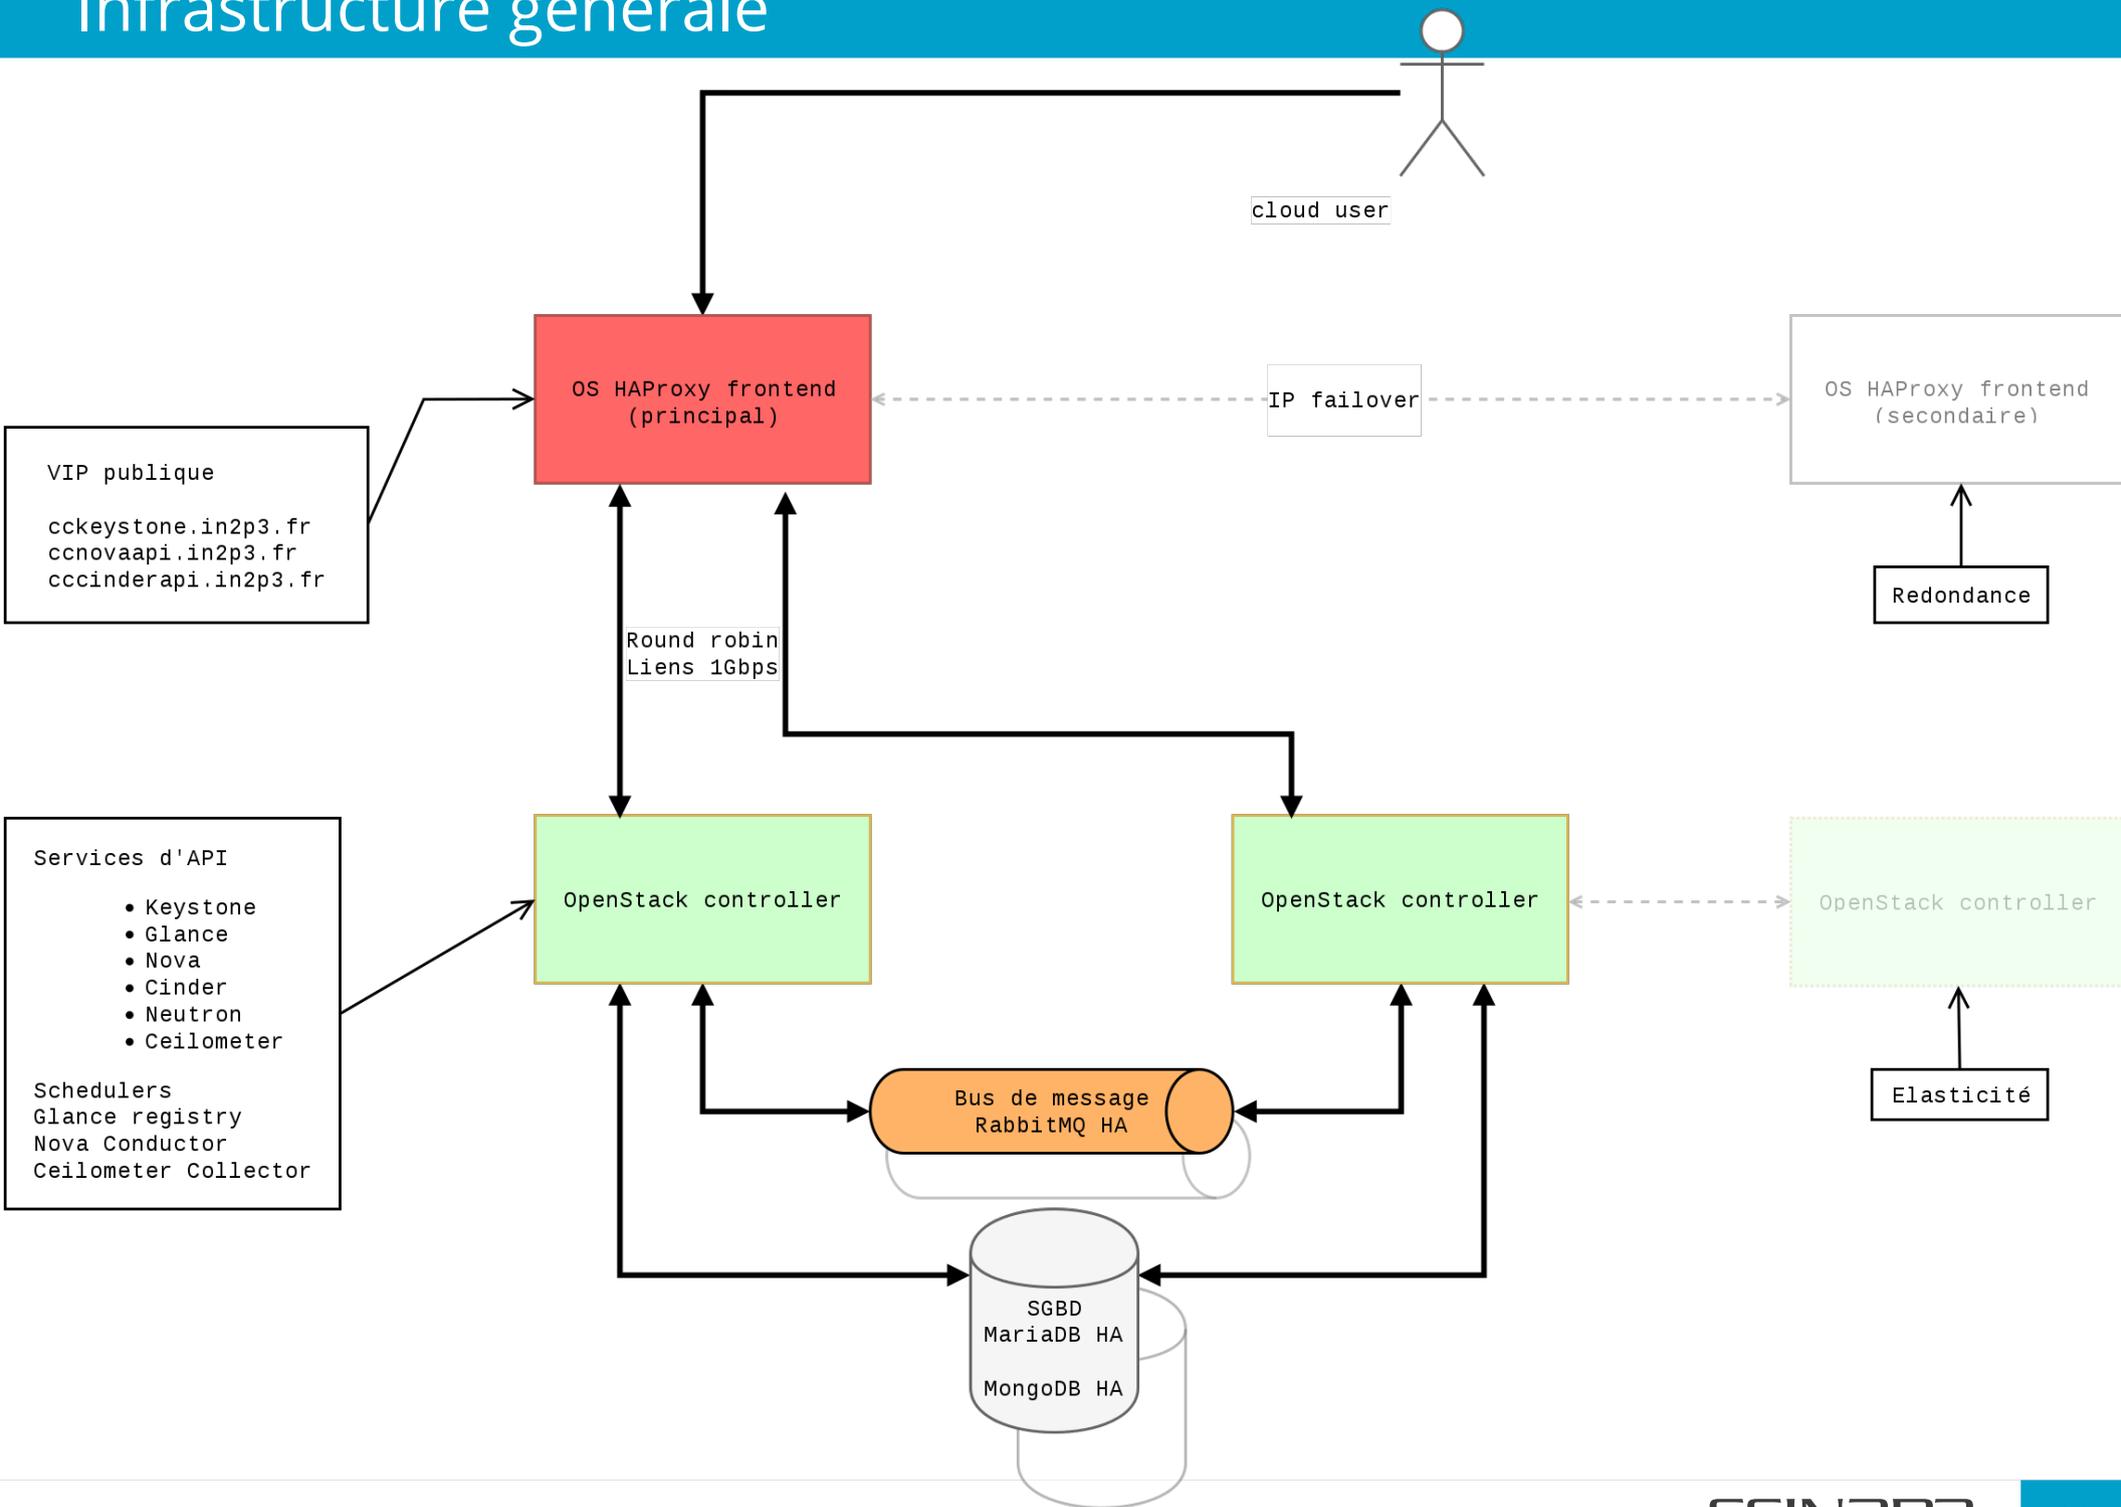
- CentOS 7
- Paquets RedHat RDO
- Déploiement et gestion de conf. par Puppet

## Hardware (mai 2016)

- R & D = 288 cœurs HT Xeon X56xx
- Prod. = 160 cœurs HT Xeon E5 26xx
- HTC = 1056 cœurs HT Xeon X56xx
- Héber. = 320 cœurs HT Xeon X56xx et E5 26xx
  - **Total de 1824 cœurs HT en production**
  
- **8905GB de RAM en production**
  
- 40TB de stockage distribué sur 10 serveurs GPFS
- 30TB de stockage orienté objet Swift
- 9TB de stockage rapide (15K) orienté block Cinder
- 24TB de stockage lent (7K2) orienté block Cinder
  - **Total de 113TB de stockage dédié au cloud**
  
- **Réseau 1/10Gbps Ethernet non bloquant**



# Infrastructure générale



Instance

Instance

Instance

Block device

Block device

Block device

Compute

- qemu-kvm-ev-2.3.0
- Libvirt 1.2.17+
- Kernel 3.10+
- CentOS 7

OpenStack compute  
QEMU KVM

OpenStack compute  
QEMU KVM

Réseau 10Gbps fibre

Cluster GPFS 4.1

- 3 réplicas@10 serveurs
- 40TB utile
- Disques 15K et 7K2 SAS
- Réseau 10Gbps

Noeud cluster GPFS  
1x10Gbps fibre

Noeud cluster GPFS  
1x10Gbps fibre

Noeud cluster GPFS  
1x10Gbps fibre

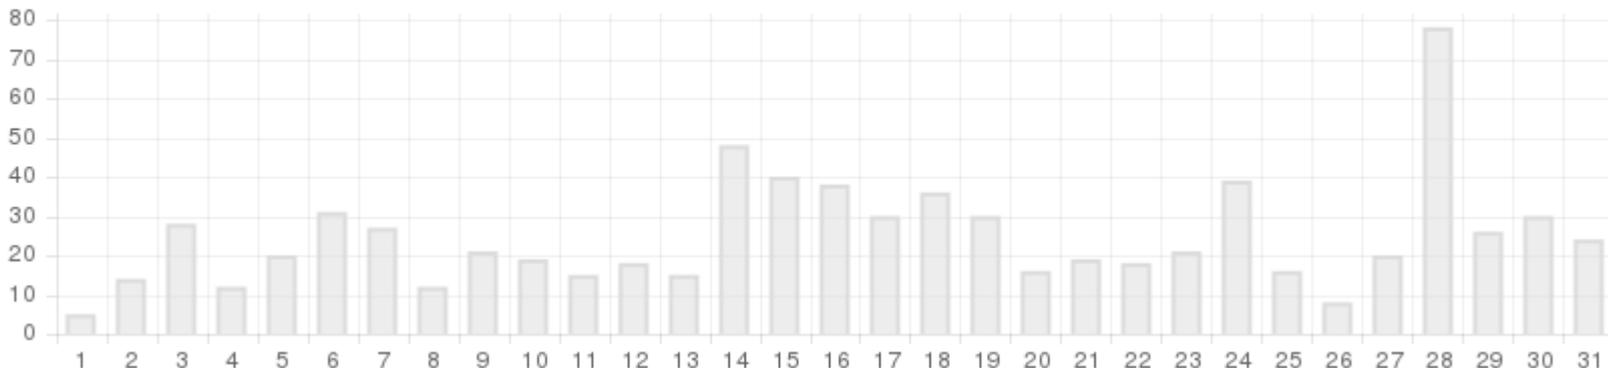
## Méthodologie

- Workflow git-flow pour toute l'équipe
  - Master – develop – feature - hotfix
- Toutes les données dans hiera (YAML)
  - Secret chiffré par GPG
- Un module site\_openstack pour tous les déploiements
- Un ENC (smurf) maison pour qualifier les machines
  - par usage (openstack)
  - et rôle (compute, controller, networking node...)
- Semantic versioning (vX.X.X)

Commit statistics for **master** Nov 05 - Sep 20

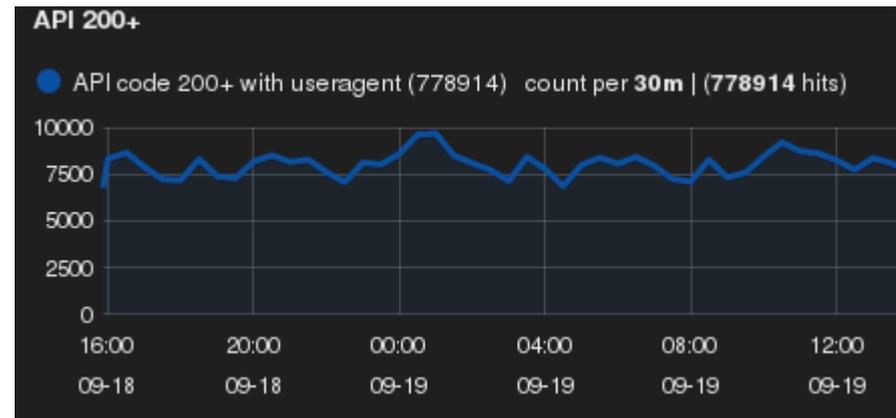
- **774** commits during **685** days
- Average **1.1** commits per day
- Contributed by **7** authors

Commits per day of month



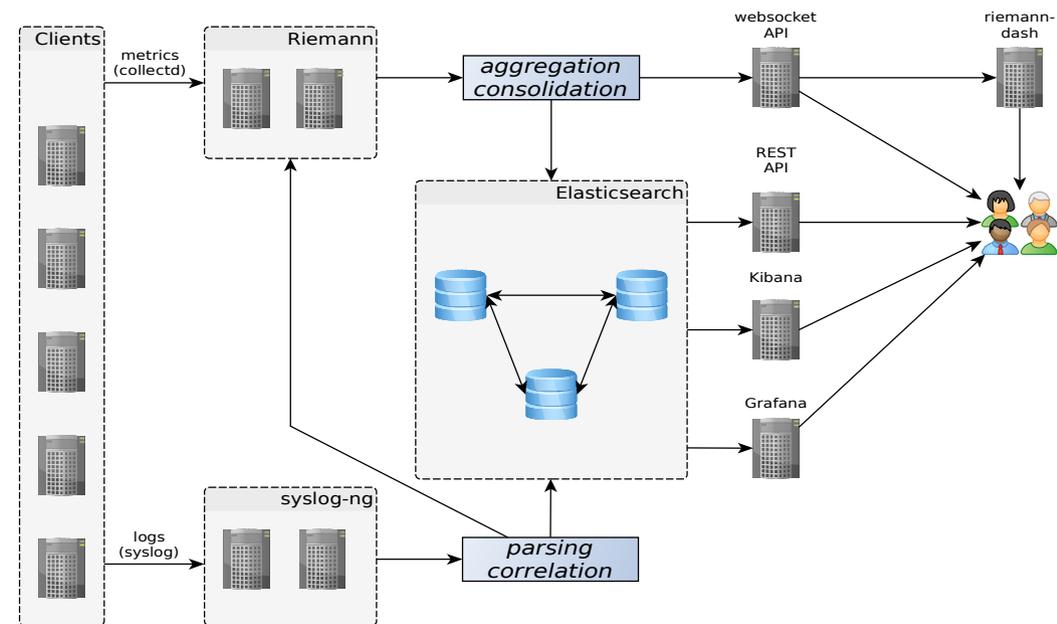
## Gestion des logs

- Collecte et envoi par syslog-ng
- Format JSON, indexé par clef
- Stocker dans Elasticsearch
- Visualisation dans Kibana
- Patch Oslo.log pour tout formater en JSON



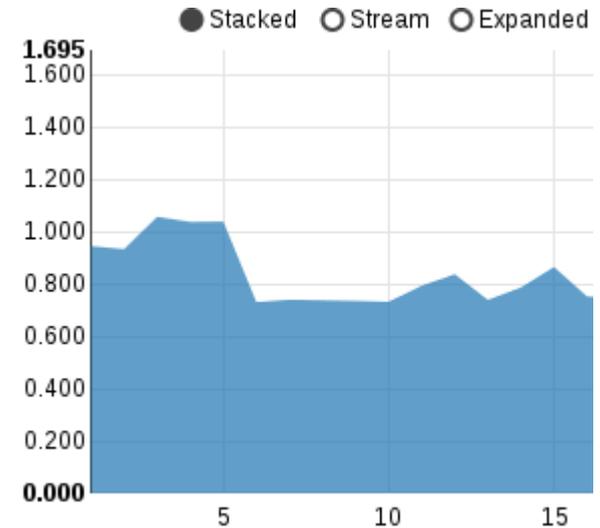
## Gestion des métriques

- Collecte et envoi par collectd
- Manipulation par Riemann
- Stocker dans Elasticsearch
- Visualisation dans Grafana



## Mise en place d'OpenStack Rally

- Déploiement Puppet
- Test de fonctionnalités, boot, delete, attach...
- Test de performance, durée d'exécution
- Historisation des comportements
- Test de Service Level Agreement



## Total durations

| Action             | Min(sec) | Median(sec) | 90%ile(sec) | 95%ile(sec) | Max(sec) | Avg(sec) | Success | Count |
|--------------------|----------|-------------|-------------|-------------|----------|----------|---------|-------|
| nova.boot_server   | 12.548   | 12.826      | 17.823      | 18.731      | 19.639   | 14.552   | 100.0%  | 5     |
| nova.reboot_server | 4.48     | 4.523       | 4.853       | 4.914       | 4.976    | 4.63     | 100.0%  | 5     |

## Gestion de la performance

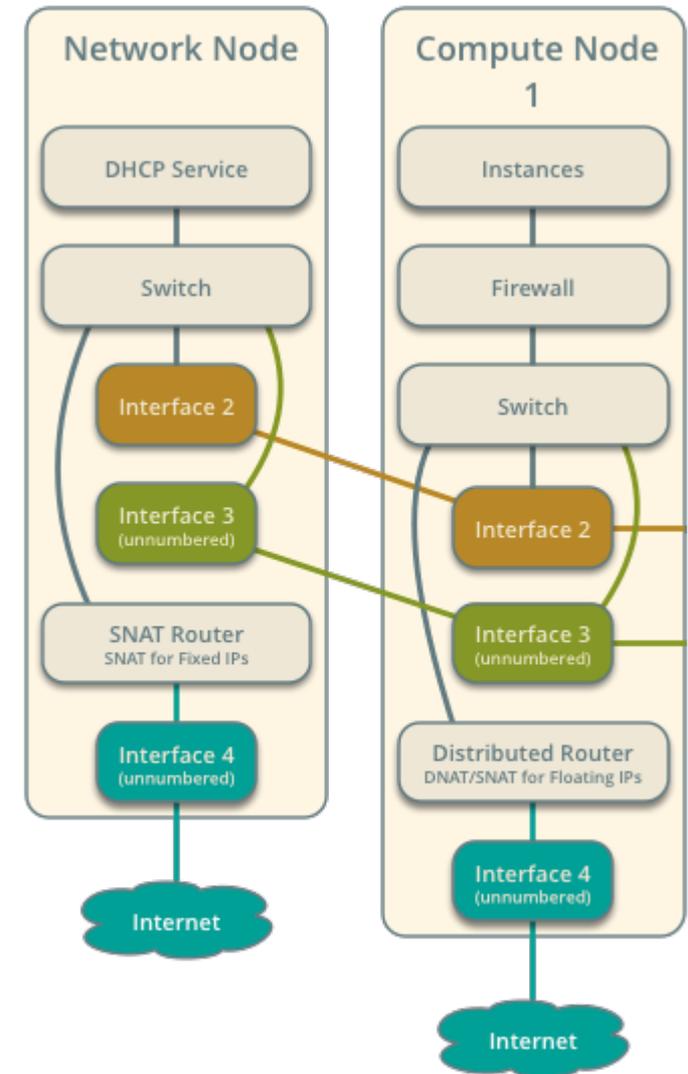
- MonteCarlo12 et HSPEC06
- Placement NUMA (bi-socket)
- Pinning de thread, pas de re-scheduling
- Hugepages de 2MB via TLBfs, - de hit/miss
- QEMU 2.3+
- Corrélation entre l'HT et la gestion cache L2
- Intel CMT & CAT pour le cache L3
- Intel Xeon E5-2680 v2 Sandy Bridge

## Migration de Nova-Network à Neutron

- Nova-network depuis ~ 2012, 30aine de VLAN
- Prévues pour Décembre 2016 sur une journée
- Passage à OpenVSwitch pour le L2
- Passage aux namespaces iptables pour le L3
- Même adressage et fonctionnalités

## Déploiement Neutron

- D'ores et déjà Puppetisé
- Testé en pré-production
- Choix du mode Distributed Virtual Router
- IPs publiques routées directement par notre Cisco Nexus
- SNAT des IPs privées pour accès Internet
- Ségrégation des projets par VLAN ou VXLAN



Tunnel network  
10.0.1.0/24

VLAN network

External network  
203.0.113.0/24

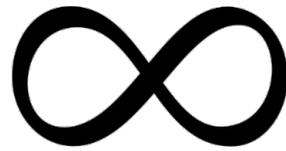


Centre de Calcul de l'Institut National de Physique Nucléaire et de Physique des Particules

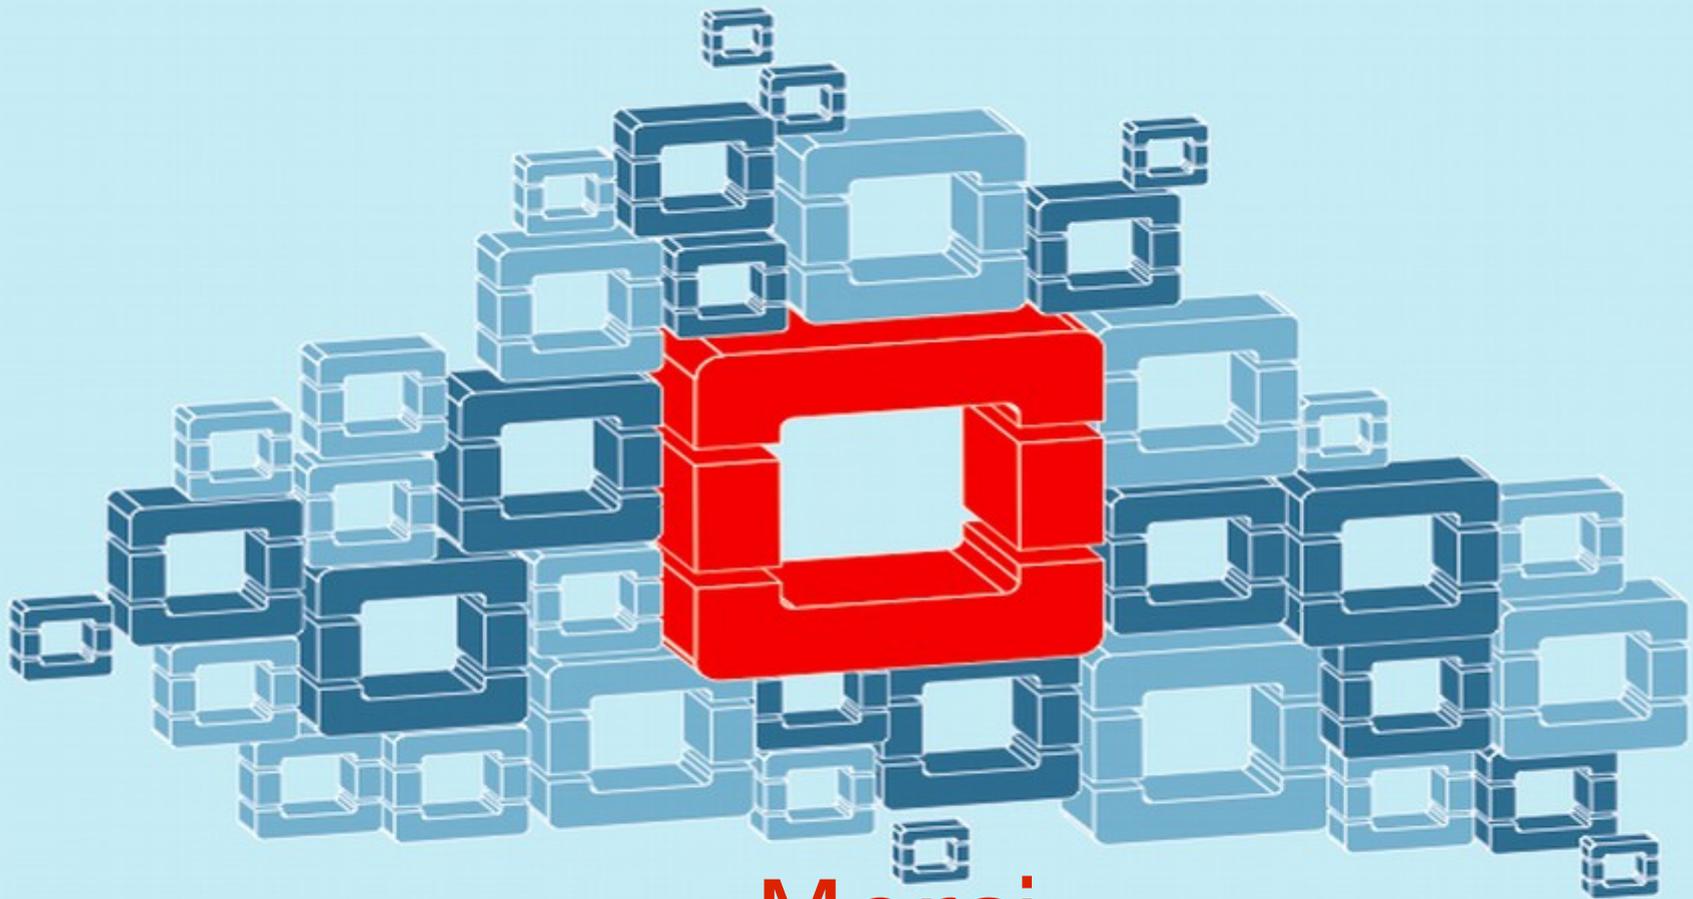
# LE FUTUR



- Fair Share Scheduling pour la fin 2016
  - Développement de la solution Synergy pour OpenStack
  - Projet européen INDIGO Datacloud
- Mise en production d'OpenStack Heat, template de déploiement
- Continuer la gestion de la performance HTC, overhead < 5 % et IO
- Finaliser la compatibilité des containers
  - Bug devicemapper
  - Ethernet LRO offloading et Intel IXGBE + ip\_forwarding/bridge = timeout
- Intégration des métriques Ceilometer dans la plateforme de BI Symod



- Récupération des ressources automatiquement (Freezer ?)
- IPv6 de bout en bout
- Étude et mise en place d'un nouveau backend Cinder
  - Probablement Ceph ou GPFS
  - Sensibilité trop importante avec LIO et ISCSI Kernel
- Travail autour de l'orchestration des containers
  - OpenShift
  - Kubernetes
- Consolidation de l'infrastructure d'images Glance
  - Séparer les flux de transfert de ceux d'API, management
  - Augmenter la capacité de transfert (snapshot, boot)
  - QoS, monitoring



Merci

Questions ?