

Distributed Systems

Doina Cristina Duma
Workshop SDDS – 18/01/2018

Panoramica

- Personale
- Gestione risorse SDDS (hard & soft)
- Progetti
 - interni/locali CNAF
 - INFN
 - Nazionali
 - Internazionali

Personale

- Vincenzo **Ciaschini** - T.I.
- Alessandro **Costantini** - T.D. (Luglio 2018)
- **Doina Cristina Duma** - T.D. (Dic. 2018, idoneità concorso T.I. 18887)
- Diego **Michelotto** - T.D. (Ago. 2018, vincitore CNAF-T3-657, idoneità concorso T.I. 18887)
- Matteo **Panella** - T.D. (Mar. 2019)

Gestione risorse SDDS

Short term – gestione hardware & software as-is

Long Term:

- Definire procedure chiare per il rinnovo parco macchine
- Ottimizzare uso risorse – vari cluster, varie tecnologie
- Migliorare qualità livello PaaS

Gestione risorse (hard) SDDS (1)

- Totale risorse a disposizione SDDS: **195 server fisici** con **~ 3700 core (con HT dove disponibile)** e **~ 10TB di RAM**
 - AMD **2012**: 68 server con ~ 1600 core e ~ 5TB di RAM (**PRODUZIONE**) (44 Donate dal Farming nel 2017, Cloud@CNAF + WN IGI BOLOGNA)
 - Intel **2012**: 12 server con ~ 280 core e ~ 500GB di RAM (**PRODUZIONE**) (oVirt di produzione)
 - AMD **2013**: 44 server con ~ 700 core e ~ 2,5TB di RAM (**PRODUZIONE**) (Cloud@CNAF) (**Sotto manutenzione fino agosto 2018**)
 - Intel **2013**: 7 server con ~ 200 core e ~ 400GB di RAM (**PRODUZIONE**) (Cloud@CNAF)
 - Intel **2017**: 3 server con ~ 110 core e ~ 600GB di RAM (INFN-CC) (**Sotto manutenzione fino 2022**)
 - Intel < **2012**: 61 server con ~ 700 core e 1,2TB di RAM (Testbed)


Gestione risorse (hard) SDDS (2)

Storage - total = **386 TB RAW, di cui FREE 138 TB**


- **Equallogic PS6010 16x600GB SAS 15K ~ 9TB RAW con RAID 50 = 6TB, di cui 3TB FREE (oVirt di Produzione)**
 - **Sotto manutenzione fino a Novembre 2018**
- **Powervault**
 - MD3660i: **60x4TB NLSAS 7.2K (Sotto manutenzione fino Aprile 2020)**
 - MD3600e: **10x6TB NLSAS 7.2K + 10x180GB SSD (Acquistato da EEE, sotto manutenzione fino Gennaio 2020)**
 - **300 TB NLSAS RAW + 1,8TB SSD RAW**
 - **~ 60TB FREE NLSAS, 100% USED SSD**
- Storage **SuperMicro (INFN-CC) 2xSSD 148GB (Sistema) + 6xSSD 500GB = 3TB RAW(Ceph) + 12xHDD 6TB = 72TB RAW (Ceph) (Sotto manutenzione fino Luglio 2022)**

Gestione risorse (hard) SDDS (3)


CPU



RAM (TB)



Storage (TB)



Gestione risorse (hard) SDDS (4)


Network

- **Router SDDS:** VDX 6740 48 porte 10Gb/s BASE-SR + 4 porte 40Gb/s BASE-SR (EQL)
- 4 switch 48 porte 1Gb/s BASE-T + uplink 10Gb/s BASE-SR
- 2 switch 24 porte 1Gb/s BASE-T + 2 10Gb/s BASE-T + uplink 10Gb/s BASE-SR (PV)
- 5 switch 48 porte 1Gb/s BASE-T + uplink 1Gb/s BASE-SR
- 1 switch 48 porte 10Gb/s BASE-T + uplink 40Gb/s BASE-SR
- 2 switch 16 porte 1Gb/s BASE-T + uplink 1Gb/s BASE-SR

Gestione risorse (soft) SDDS (1)

oVirt

- **DC Production**
 - 10 Server con 240 core e 480GB RAM
 - 3TB da Equallogic
 - **72 VM** (Servizi GRID, Servizi SDDS, Servizi CNAF, Servizi INDIGO, Servizi Bebop)
- **DC Testbed**
 - 18 Server con 144 core e 288GB RAM
 - 4TB da PowerVault
 - **79 VM** (Vari testbed, Servizi Cloud@CNAF)
- **DC INFN-CC**
 - 4 Server con 64 core e 256GB RAM
 - 1 TB da PowerVault
 - **6 VM** (Servizi INFN-CC)



Gestione risorse (soft) SDDS (2)

Openstack

- Produzione
 - 3 MySQL Percona DB, 5 RabbitMQ (VM), 2 HAProxy + Keepalived (VM)
 - 16TB GPFS da PowerVault (Dischi Dedicati + Metadati su SSD)
 - 2 Controller Node, 2 Network Node
 - **65 Compute Node: ~400 Core, ~4.6TB RAM, 16TB shared Storage e 44TB Local IO Storage**
 - 164 VM
- Testbed Upgrade
 - 3 MySQL Percona DB (VM), 3 RabbitMQ (VM), 2 HAProxy + Keepalived (VM)
 - 2TB GPFS da PowerVault
 - 2 Controller Node, 2 Network Node, 2 Compute node

Gestione risorse (soft) SDDS (3)

Grid

○ NGI_IT

- Gestione Alias DNS su dominio grid.cnaf.infn.it + Check (sensu) di gestione automatica dell'alias per:
 - **2 LFC per 26 VO**, composto da 2 VM ciascuno con HA via DNS, dati su DB MySQL Percona. **(In dismissione)**
 - **TopBDII** egee-bdii.cnaf.infn.it 5 host (4 VM al CNAF 1 a PD)
 - **WMS** wms-multi.grid.cnaf.infn.it per **31 VO**, 7 host (4 Macchine CNAF, 2 CT, 1 FE) **(In dismissione)**
 - **MyProxy** - myproxy.cnaf.infn.it 2 host con shared filesystem su GlusterFS (2 VM al CNAF)
 - **Squid** - squid.grid.cnaf.infn.it 2 host (2 VM al CNAF)
- **3 VOMS per 28 VO**, 2 repliche a PD e 1 a NA
- **Argus** centrale per NGI_IT (1 VM al CNAF)
- **IGI Portal** (1 Macchina e 3 VM)

Gestione risorse (soft) SDDS (4)

Grid

- **IGI-BOLOGNA**
 - 24 WN ~500 job slot per 5 VO
 - 1 SE/StoRM da 10 TB per 6 VO
 - 1 CE (VM)
 - 1 Argus di sito (VM)
 - 1 SiteBDII composto da 2 VM in HA tramite DNS

VMWare

- 2 CVMFS server

Gestione risorse (soft) SDDS (6)

- Cluster **GPFS**
 - 2 Server, 1 quorum node, 67 client con accesso diretto ai dischi
 - 2 NSD da 8TB da 2 Disk Group da PowerVault ciascuno da 4 Dischi da 4TB in RAID 10 per dati
 - 2 NSD da 180GB da 2 Disk Group da PowerVault ciascuno da 2 Dischi SSD da 180GB in RAID 1 per metadati
 - 12 NSD da 3TB da Volume Group da PowerVault per un totale di **32TB per FS EEE** (su 60TB richiesti dal progetto)
- **GlusterFS**
 - 3 Nodi
 - 6 volumi in replica 3, ogni nodo monta un disco da PowerVault per ogni volume per un totale di 2.3TB per nodo
 - Volumi usati per **MyProxy, Central Logging servizi Grid, Jenkins, MPI shared home.**

Gestione risorse (soft) SDDS (7)

- **CEPH**
 - 3 MON server virtuali
 - 4 OSD server con ciascuno un osd da 2TB
 - Installazione automatizzata del cluster via Puppet
 - Test di valutazione Ceph come storage backend di Openstack
- **Testbed Mesos/Marathon**
 - 3 nodi fisici ciascuno con ruolo mesos-master, mesos-slave, etcd, marathon e chronos.
 - Test di integrazione con Jenkins.
 - Test di autoscaling dei worker HTCondor.
 - Test preliminari del progetto HTMesos (Vedi slide successive)

Gestione risorse SDDS

Risorse perse causa allagamento

- 4 Compute node Cloud@CNAF
- 1 DB server Cloud@CNAF + 1 lavato e recuperato
- 1 Storage INFN-CC
- 2 Macchine portale IGI (recuperato immagine disco)
- 1 m1000e con 8 M600 (Dell)

Risorse a disposizione dopo l'allagamento

- **Cloud@Bari** - K8s@MW (7 VM), Tool INDIGO IAM + tool collaborativi (4 VM)
- **SDDS@Ferrara** (Ripristinata la produzione di SDDS)
 - Hardware
 - PowerVault + EqualLogic > 300TB RAW
 - 4 Switch
 - 2 Network Node
 - 2 Compute Node
 - 2 GPFS server
 - 1 Backup Server
 - **3 Huawei Farming (24 server con 40 core e 128GB)**
 - 5 nodi oVirt, 3 nodi DB, 1 nodo di servizio, 1 nodo cloud-ui, 9 compute node, 5 Nodi spare
 - Servizi
 - NGI_IT
 - Cloud@CNAF (EEE, FAZIA/US, INDIGO PaaS)
 - Consumi inferiori a 14kW dei 20 a disposizione.

Grid

Partecipazione EGI

- Coordinamento NGI_IT, sito IGI-Bologna, Servizi core
- Partecipazione EGI-CSIRT (Computer Security Incident Response Team)
- IGI-Portal - user support
- **Attività**
 - IPv6 – RC readiness plans
 - Decommissioning campaigns - dCache 2.13, WMS EOL -1 Jan. 2018 (calet.org, compchem, theophys, virgo, xenon)
 - Storage Accounting Deployment (DPM&dCache)

Cloud

- **Cloud & CNAF**

- **Miglioramenti**

- **Affidabilità** - Deployment nuovi cluster DB, RabbitMQ, separati
- **Qualità - Aumentato risorse**
 - 20 Hypervisors (compute) con storage locale (40TB)
 - Risorse totali: - 66 hypervisors/compute nodes

- **Nuovi use case** – FAZIA (~15VM, 256CPU, disco 1,2TB+2 , 5TB (16x160GB))

- **Attività :**

- Integrazione INDIGO-IAM
- Deployment INDIGO PaaS – Orchestrator, Infrastructure Manager, SLA Manager, CMDB,..
- KUBE = messa in produzione di un cluster Kubernetes per deployment servizi-in-container (IAM, TTS)
- CEPH come backend per alcuni servizi OpenStack
- Miglioramento collegamenti connessioni Computes<->PV – 2 nuovi sw per rack 206-10
- Accounting – Ceilometer+Gnocchi
- Monitoring – definizione nuove probe/check “cloud” per Sensu
- Upgrade (Mitaka->Newton->Ocata->Pike)

Strumenti per la gestione risorse SDDS

- **Foreman/Puppet - provisioning e configurazione automatica**
 - Contributo alla realizzazione e utilizzo dell'infrastruttura comune per il CNAF (Vedi progetto Bebop)
 - Servizi specifici per SDDS gestiti via foreman-provy
 - DHCP
 - TFTP
 - DNS
- **Sensu, Uchiwa, Grafana - monitoring & allarmistica**
 - Contributo alla realizzazione e utilizzo dell'infrastruttura comune per il CNAF (Vedi progetto Bebop)
 - Servizi specifici per SDDS
 - Sensu-server
 - Uchiwa dashboard
 - Grafana dashboard
 - InfluxDB
- **Rundeck** - Integrato con Foreman, per le risorse SDDS.

Progetti

Progetti - interni/locali - CNAF

- Dynamic Farm
- Data Housing
- WNodeS
- BEBOP

Dynamic Farm

- Permette di usare WN esterni al CNAF come se fossero interni
 - **Collaborazione con T1-Network**
 - Usato per WN su Azure, Aruba, HNSciCloud
 - Requisiti sulle macchine remote minimi (outbound connectivity, subnet su cui mettere le macchine)
 - Sui forniscono anche tool di amministrazione batch remota

DataHousing

- Sistema per permettere l'accesso senza certificato ai nostri server di dati (basati su gridftp)
 - **Collaborazione con User Support**
 - Non richiede installazione
 - Autenticazione basata su Kerberos del CNAF
 - Gestione dei certificati/proxy VOMS completamente nascosta
 - Per lo Rep. Storage un esperimento e' semplicemente una nuova VO
 - Aggiornamento automatico di versione in versione
 - Testato/Usato da cuore, dampe, km3, etc...
 - Correntemente versione 12/client 1.4.5/server

WNodeS

- Creazione on demand di VM per esperimenti con necessita' di setup particolari.
 - Attualmente sospeso causa fine dello use case per il T1
 - Prima della sospensione era in mantenimento
 - Non c'erano bug o problemi noti
 - Non c'era necessita' di nuove feature

BEBOP

Partecipazione al gruppo trasversale del CNAF per la progettazione e realizzazione delle infrastrutture centralizzate per:

- **Provisioning**
 - Utilizzo di Foreman e Puppet per il provisioning e la configurazioni della macchine del CNAF
 - Dimensionamento dei servizio per i numeri del CNAF
 - Alta disponibilità dei servizi
- **Monitoring**
 - Realizzazione delle infrastrutture centrali per il supporto del monitoring basato su Sensu
 - Cluster RabbitMQ per comunicazione tra server e client di sensu
 - Redis + Redis Sentinel archiviazione stato dei check
 - InfluxDB per archiviazione di metriche (Time series DB)
 - Realizzazione di classi puppet per i vari reparti del CNAF per installazione e configurazione di Sensu (1 o più per ogni reparto)
- **Logging**
 - Realizzazione di testbed, ospitati da SDDS, per la realizzazione di una infrastruttura comune al CNAF per archiviazione ed indicizzazione di log basati sullo stack ELK.

Risorse SDDS: - 1 Sensu Server, 1 InfluxDB, 15 VM oVirt + 1,5TB da PowerVault per Logging, Provisioning e Logging upgrade testbed su Cloud@CNAF 10VM

Progetti - INFN

INFN-CC

- a geographically distributed private cloud infrastructure, based on OpenStack, that has recently been deployed in three of the major INFN data-centres in Italy, fully redundant and resilient architecture to provide critical network services for the INFN community
 - deploy a PaaS layer by adopting services developed within the EU funded project INDIGO-DataCloud
- **Attività**
 - progettazione dell'architettura
 - Provisioning e manutenzione delle risorse & servizi:
 - Foreman/Puppet, openVPN, DNS, DHCP, HAProxy, Cluster MySQL, CEPH, Zabbix (server + proxy), Logging (syslog-ng)
 - Openstack (Keystone, Glance, RabbitMQ)
- **Collaborazione - SDDS, Sistemi Nazionali, Rete**

HTMESOS

- Implementazione di un servizio di “Batch Farm on-demand” a livello PaaS basato su HTCondor e Mesos.
 - i vari daemon HTCondor - Docker container - preconfigurati e distribuiti come Long Running Service (LRS) attraverso Marathon
- **Risultato:** INFN-TO -> **Open Computing Cluster per Advanced Data Manipulation (OCCAM)**, una struttura HPC volta a fornire un'infrastruttura flessibile e multifunzionale (Poster @ INDIGO Summit 2017)
- **Attività**
 - Contributi alla progettazione architettonica e alla creazione di contenitori, config. con ansible => **DODAS**
 - Provisioning e manutenzione delle risorse

Progetti Nazionali

- OCP - finito
- Cagliari2020 - possibile


OCP

Progetto finanziato dal MIUR ,a guida INFN, partecipazione pubblico/privato - finito

- ricerca, sviluppo e sperimentazione di nuove soluzioni tecnologiche open, interoperabili utilizzabili on-demand nell'ambito del Cloud Computing per le Pubbliche Amministrazioni
- ultimi deliverables e SAL (stato av. Lavori) per tutti I semestri
- Validazione piattaforma OCP, in particolare la parte IaaS, presso le enti/regioni sperimentatrici

Attività

- Automazione
 - Sviluppo di strumenti e procedure per installazione automatica di tutti i componenti IaaS e loro upgrade
 - AutomaticOCP: Know-how applicato per l'upgrade di Cloud@CNAF (Juno->Mitka)
- Monitoring applicativo - **interfaccia web** per il monitoring applicativo
- Supporto e documentazione
 - Supporto per le attività di installazione e configurazione IaaS nei testbed regionali
 - Supporto alle attività di **mantenimento e risoluzione problematiche** per i testbed regionali
 - Scrittura **documentazione** e mantenimento (ove necessario)
 - Guide installazione, Documenti di validazione, Presentazioni Enti e Regioni
- Corsi OpenStack



Cagliari2020

Progetto finanziato dal MIUR a guida Crs4 (Centro di Ricerca, Sviluppo e Studi della Sardegna) che ha tra i capofila INFN-Cagliari, Partecipazione pubblico/privato

- Sviluppo di strumenti e soluzioni tecnologiche per l'ottimizzazione della mobilità urbana
 - Def. requisiti per soluzioni cloud IaaS e SaaS
 - **Sviluppo di specifici strumenti per l'integrazione su piattaforme cloud delle applicazioni per l'analisi e l'elaborazione dei dati e supporto all'operatività.**
 - Studio di soluzioni cloud coerenti con le esigenze di progetto & Porting delle applicazioni su infrastrutture IaaS/SaaS

Attività

- installazione di una infrastruttura cloud OpenStack via **AutomaticOCP**
- descrizione dei deliverable INDIGO su requirement tecnologici (IaaS, PaaS e SaaS)
- integrazione di INDIGO **IAM** in OpenStack, installazione/uso **TTS** (WaTTS & WaTTson)
- **PaaS** - installazione IM, Orchestrator
- installazione di **Oneprovider** (agganciato alla onezone del CNAF) e prove di Onedata per accesso dati - eventualmente data replication
- istanziazione di cluster Mesos / batch system on-demand via TOSCA template (DODAS o simile)
- **udocker** - uso; portali - FG

Progetti Internazionali

- INDIGO - DataCloud - finito
- EOSCpilot - in corso
- XDC, DEEP, EOSChub - nuovi

INDIGO-DataCloud

“Develop an open source data and computing platform - targeted at scientific communities - helping developers, resources providers, e-infrastructures and scientific communities to overcome current challenges in the Cloud computing, storage and network areas”

Attività:

- Software lifecycle management
 - Release - CI, repositories, documentation
- Support Services - OpenProject, agenda, owncloud ...
- Preview testbed
 - PaaS
 - Onedata - CMS/DODAS, ICCU - MuseID (e-Cultural Science Gateway)

EOSCpilot

The European Open Science Cloud for Research Pilot Project

- Develop **demonstrators of integrated services and infrastructures** in a number of scientific domains, showcasing interoperability and its benefits;


Objectives:

- Research and Data Interoperability
- Infrastructure interoperability - Demonstrate with multi-infrastructure, multi-community pilots

Key Output: - The design of a future EOSC based on federated interoperable services meeting the needs of the thematic research domains and wider user base

Tasks:

- T6.1: gap analysis & interoperability architecture [CNRS lead]
- T6.2: EOSC Research and Data interoperability [ELIXIR lead]
- **T6.3: Interoperability pilots [INFN lead]**



Nuovi progetti

eXtreme – DataCloud

- developing scalable technologies for federating storage resources and managing data in highly distributed computing environments, as required by the most demanding, data intensive research experiments in Europe and worldwide

DEEP-Hybrid – DataCloud

- support intensive computing techniques that require specialized HPC hardware to explore very large data
- deploy under the common label of “DEEP as a Service” a set of building blocks that enable the easy development of applications requiring these techniques: - deep learning using neural networks; parallel post-processing of very large data; analysis of massive online data streams.

EOSCHub

- Integrating and managing services for the European Open Science Cloud

Attività

- Preparazione proposta progetto XDC & DEEP
- XDC & DEEP
 - WP1 - Project management
 - WP3 - SW management, SQA, Pilot testbed (inclusi tool – collaborativi)
- EOSCHub - supporto DODAS (Thematic Service)