Leonardo Opportunistico stato e prossimi passi

Tommaso/Daniele

Recap stato attuale

Sono stati ripristinati, migliorati dove possibile e testati tutti e quattro gli assets come nelle precedenti macchine (A2 e M100)

- Runtime environment
- Rete - outbound connectivity
- Accesso dati esperimento da CNAF e da federazioni
- Meccanismo pressione per l’acquisizione dei nodi

Nodo edge dedicato

Nel contesto delle attività ICSC (Spoke0) abbiamo ottenuto un nodo di edge al CINECA (icsc01-ext.leonardo.cineca.it + IP interno CINECA)

- È configurato come un nodo di login accessibile ssh solo da CNAF
- Lo usiamo per gestire scripts per la pressione
- Ci serve per integrare la parte cloud infn con leonardo via offloading
    - Ci facciamo girare interLink

Non siamo amministratori è solo un nodo dedicato che può offrirci qualche maniglia per far funzionare i nostri workflow

- Vedi dopo

Runtime environment

CVMFS con afuse

- Il setup di Leonardo è fatto per isolare tutto con "job_container" slurm
- Per montare il client serve una soluzione tutta in userspace, perchè interna al mount namespace della shell istanziata da slurm
  - Hanno proposto di usare questo https://github.com/pcarrier/afuse
  - Tutto automatizzato usando una convenzione per il job name
    - srun -t 1400 -A inf24_lhc_2 --pty -p dcgp_usr_prod --ntasks=1 -J AA**_CVMFS_**BB --cpus-per-task=1 bash

Abbiamo montato i repositories CERN e fatto configurare i repo pubblici INFN (datacloud.infn.it e unpacked.infn.it)

- Ci serve per le dipendenze WN
  - source /cvmfs/datacloud.infn.it/repo/wn-leonardo/v1/etc/profile.d/wn-leonardo-setup.sh
  - In questo modo, il pilot gira sul sistema standard e NON dentro un container singularity (M100)
- Abbiamo un CVMFS publisher (VM su cloud CNAF) disponibile per pubblicare quello che serve sui repo INFN

Outbound connectivity

Sui nodi slurm (sia GP che Booster) sono aperti outbound

- Tutto il CERN “computing center”
- Tutto il CNAF, sia il Tier1 che la parte Cloud
- Nodi selezionati FNAL (per accedere a servizi CMS – non indispensabile ma utile)

È un pochino di più di quanto avevamo su M100 e A2. Se serve qualcosa ancora credo si possa negoziare

- Dovrebbe sicuramente bastare per gli LHC con la limitazione nota dell’accesso ai dati fuori dal Tier1 CNAF (vedi dopo)

Accesso ai dati

Lettura e scrittura su Tier1 CNAF testato e funziona

- Per CMS stiamo usando:
  - `davs://xfer-cms.cr.cnaf.infn.it:8443/cmsdisk`
- Per leggere dalla federazione abbiamo ripristinato il proxy xrootd. Per ora una VM su cloud CNAF (non carrozzata)

La logica per l'accesso ai dati in cms è: Priorità su CNAF e fallback sulla federazione passando dal proxy

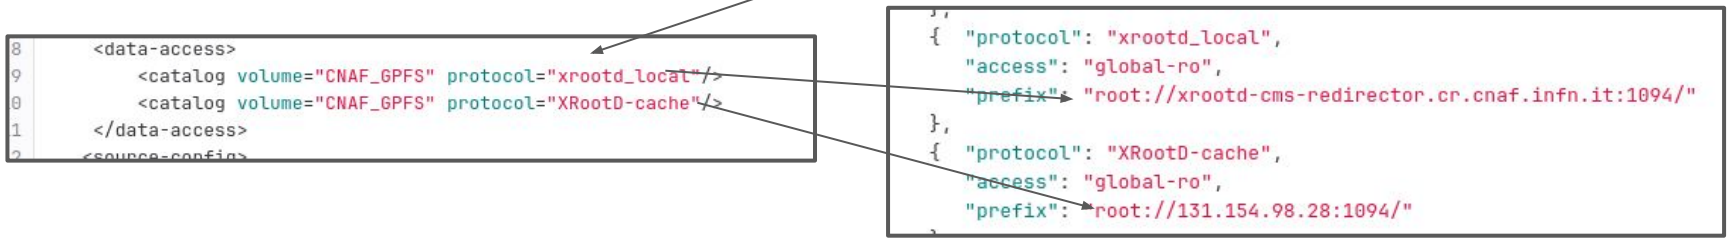

Questo è CMS specific ma il "setup del proxy" può essere replicato per tutti

Meccanismo di pressione / creazione pilot

- NON usiamo al momento jobs pilot sottomessi tramite il CE (prossimo passo), ma usiamo il meccanismo dei **manual_glidein**; in questo modo serve sottomissione di jobs SLURM che facciano partire pilots
  - GitHub: https://github.com/tommasoboccali/leonardo_opportunistic
- Meccanismo di pressione che funziona su GP e Booster, basato su files di configurazione
  - `{"jobexecutor": "./slurm_glidein_dcgp_lowprio.job", "log_prefix": "logs/gp_job_log_", "jobname": "GP_CMS_GLIDEIN_CVMFS_JOB", "max_running": 100, "max_idle": 5, "max_hours": 20000}`
  - Meccanismo dinamico: modificando il file, si possono cambiare runtime i parametri (per esempio aumentare / diminuire il numero di jobs running / in attesa)
  - **In realizzazione** meccanismo che lo faccia automaticamente guardando quanti pilot sono agganciati dal payload (quindi auto-tune del numero di jobs)
- Importante: "`_lowprio":` abbiamo avuto accesso a una coda low priority, NON accountata ("gratis") → possiamo implementare un meccanismo davvero opportunistico, alla backfill

Tests con meccanismo di pressione

```
[tboccali@login07 leonardo_opportunistic]$ squeue --me
             JOBID PARTITION     NAME     USER ST       TIME  NODES NODELIST(REASON)
           5985766 dcgp_usr_ GP_CMS_G tboccali PD       0:00      1 (Priority)
           5985763 dcgp_usr_ GP_CMS_G tboccali PD       0:00      1 (Priority)
           5985448 dcgp_usr_ GP_CMS_G tboccali  R       9:41      1 lrdn4394
           5985450 dcgp_usr_ GP_CMS_G tboccali  R       9:41      1 lrdn4432
           5985429 dcgp_usr_ GP_CMS_G tboccali  R      10:39      1 lrdn4313
           5985430 dcgp_usr_ GP_CMS_G tboccali  R      10:39      1 lrdn4357
           5985417 dcgp_usr_ GP_CMS_G tboccali  R      11:41      1 lrdn3997
           5985418 dcgp_usr_ GP_CMS_G tboccali  R      11:41      1 lrdn4158
           5985389 dcgp_usr_ GP_CMS_G tboccali  R      12:42      1 lrdn4947
           5985390 dcgp_usr_ GP_CMS_G tboccali  R      12:42      1 lrdn3883
           5985378 dcgp_usr_ GP_CMS_G tboccali  R      13:43      1 lrdn3745
           5985379 dcgp_usr_ GP_CMS_G tboccali  R      13:43      1 lrdn3845
           5985352 dcgp_usr_ GP_CMS_G tboccali  R      14:46      1 lrdn4687
           5985353 dcgp_usr_ GP_CMS_G tboccali  R      14:46      1 lrdn4847
           5985342 dcgp_usr_ GP_CMS_G tboccali  R      15:41      1 lrdn4356
           5985344 dcgp_usr_ GP_CMS_G tboccali  R      15:41      1 lrdn4570
           5985341 dcgp_usr_ GP_CMS_G tboccali  R      16:42      1 lrdn4681
           5985317 dcgp_usr_ GP_CMS_G tboccali  R      16:49      1 lrdn3850
           5985318 dcgp_usr_ GP_CMS_G tboccali  R      16:49      1 lrdn4567
           5985309 dcgp_usr_ GP_CMS_G tboccali  R      17:40      1 lrdn4551
           5985310 dcgp_usr_ GP_CMS_G tboccali  R      17:40      1 lrdn4915
           5985125 dcgp_usr_ GP_CMS_G tboccali  R      27:08      1 lrdn4935
           5985130 dcgp_usr_ GP_CMS_G tboccali  R      27:08      1 lrdn4309
           5985627 dcgp_usr_ GP_CMS_G tboccali  R       4:27      1 lrdn4469
           5985630 dcgp_usr_ GP_CMS_G tboccali  R       4:27      1 lrdn4573
           5985642 dcgp_usr_ GP_CMS_G tboccali  R       3:39      1 lrdn4603
           5985643 dcgp_usr_ GP_CMS_G tboccali  R       3:39      1 lrdn4609
           5985694 dcgp_usr_ GP_CMS_G tboccali  R       0:40      1 lrdn4154
           5985697 dcgp_usr_ GP_CMS_G tboccali  R       0:40      1 lrdn4310
           5985658 dcgp_usr_ GP_CMS_G tboccali  R       1:40      1 lrdn4245
           5985660 dcgp_usr_ GP_CMS_G tboccali  R       1:40      1 lrdn4261
           5985649 dcgp_usr_ GP_CMS_G tboccali  R       2:41      1 lrdn4618
           5985650 dcgp_usr_ GP_CMS_G tboccali  R       2:41      1 lrdn4685
```

Test con 40 nodi = 4480 cores

Meccanismo di pressione che gira su un tmux sul nostro nodo edge (accessibile direttamente da CNAF)

```
=== Date: 2024-07-18 16:34:48.924652
(running, pending) = (10,0)
Starting 10 jobs.
Submitted job logs/gp_job_log_1721313288
Submitted job logs/gp_job_log_1721313290
Submitted job logs/gp_job_log_1721313291
Submitted job logs/gp_job_log_1721313292
Submitted job logs/gp_job_log_1721313293
Submitted job logs/gp_job_log_1721313294
Submitted job logs/gp_job_log_1721313296
Submitted job logs/gp_job_log_1721313297
Submitted job logs/gp_job_log_1721313298
Submitted job logs/gp_job_log_1721313299
Current Max_Running 100
Current Max_Pending 10
Cycles missing:  3599
```

Primi test con Virtual Kubelet

Istanziato JupyterLab su Leonardo Booster usando un k8s al CNAF e interLink su edge node come test per le attività del deliverable MS8 di Spoke0

Sarà il playground per integrare altri workflow nel contesto ICSC (spoke>0)

- Piano di lavoro in progress.

Aperto a qualunque test anche se non presente nelle attività specifiche di ICSC

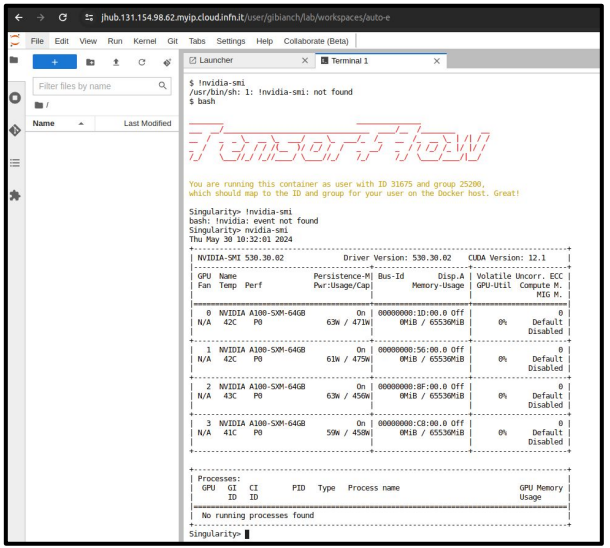

Prossimi passi: Integrazione con batch Tier1

Sul fine vita di M100 avevamo fatto una prima prototipizzazione del modello di integrazione con il batch del Tier1 sostanzialmente basato su

- Attivazione di startd (opportunamente configurati) via slurm
- Implementazione del routing a livello di CE
  - Se serve può implementare “filtro” per alcune Tipologie di job (- *want opportunistic*-)
    - Per CMS non è necessario

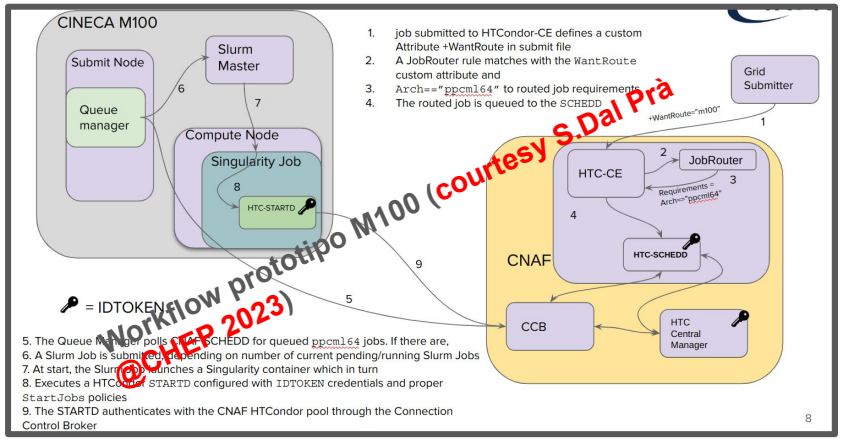

Workflow prototipo M100 (courtesy S.Dal Prà @CHEP 2023)

Mancava un meccanismo di pressione

- Ora possiamo usare quello appena mostrato
  - Eventualmente estendibile con un piccolo Check sullo stato dello schedd

Probabilmente è molto sinergico al Modello ASI di N.Mori et al