

XCache deployment@CNAF per CMS

Daniele Spiga



Cache@CMS-ITA: Cosa abbiamo fatto come INFN negli anni

E' un aspetto su cui abbiamo investito molto dal 2017

- Ma le prime slides dove si parla di cache circolavano almeno nel 2016 (Tommaso & Alessandro)

Investimenti CMS-INFN e attività :

- Borsa INFN per attività di R&D Calcolo per LHC
- Sviluppo fatta nel progetto XDC (Smart Cache)
- Test con il progetto HelixNebula SciCloud
- Sviluppo in corso nel progetto ESCAPE
 - Data lake prototype + cache + token etc...
- Setup “production ready” nell’integrazione @CINECA

2017




Oggi



Cache Network IN

2.8Gbps network inbound




Cloud@TSystem




Cache Network OUT

2.8Gbps outbound network



INFN Testbed



Disk usage cineca



XCache @ CINECA

spiga@pg.infn.it

CdG 19.02.1

Data to Clients

Data from remote




Opportunistic

Cosa abbiamo imparato finora

Sicuramente che sappiamo usare le cache, sappiamo farlo in varie configurazioni, e.g. cache gerarchiche, e che le sappiamo “customizzare” (plugin/configurazioni)

Cache effect on CPU efficiency @ CMS

- We studied monitoring data of the whole **2018 CMS analysis workflows**
 - Remote data read costs on average **about 15% of CPU time w.r.t. Onsite data reading**



Caches allow to reduce the overall WAN traffic and, makes the processing job that requested the data **more efficient** by reducing I/O wait time for remote data.

Buon impatto sull'efficienza

Possiamo ottimizzare le configurazioni




20 TB SSD cache is smallish, especially when doing analysis (we need better cache policies)



Le Cache @CMS

Non è un interesse INFN. US-CMS ha investito molto sviluppando il progetto SoCal, e ora anche il CERN (vedi dopo) e anche gli Spagnoli ci stanno guardando

SoCal Cache idea: Two caches become one



Di cosa fanno caching?

- /**/MINIAOD
- /**/MINIAODSIM

(Circa 8 PB Totale)

- 120 Miles
- 100 Gbit/sec
- 3ms

US - CMS

	UCSD	Caltech
Nodes	11 (+1 JBOD)	2*
Disk Capacity per node	12 x 2TB = 24TB (+ 48 x 11TB)	30 x 6TB (HGST Ultrastar 7K6000)
Network Card per node	10 Gbps (+ 40 Gbps)	40 Gbps
Total Disk Capacity	264 TB (+ 528 TB) = 792 TB	360 TB*
TOTAL	792 TB + 360 TB* = 1,152 TB	

CMS-CERN e XCache


CMS ha proposto di esporre alla comunità, un'opzione per accedere a NanoAOD e i MiniAOD non presenti :

- Tradotto: schierare un'istanza xCache al CERN e testarla come soluzione per leggere tutti i Nano e i Mini che non sono su EOS
 - Successivamente fare comparazioni tra varie configurazioni staging vs proxy

Inoltre: O&C ha proposto a CMS-Ita di gestire questa iniziativa e di farlo in collaborazione con le nostre attività

- Tradotto: fare quindi un setup al CNAF simile (ma non identico, prox slide)

Il lavoro al CERN è partito (per mano INFN) e lo stato dei lavori è abbastanza avanzato (setup iniziale pronto e in fase di puppetizzazione)





Cosa vogliamo fare noi (un po di numeri)

La proposta è di implementare la seguente architettura:

- Schierare una cache al Tier1 (cache di livello 2) con una quantità di disco dell'ordine di 50 TB, per i NanoAOD
 - Successivamente capiamo cosa vogliamo fare coi Mini
- Questa deve alimentare una serie di caches (primo livello) eventualmente veloci e distribuite dove si fa l'analisi
 - In linea di principio “dove si fa analisi” può essere “qualunque” cosa: una singola macchina o un cluster dislocati nei centri di calcolo italiani (vedi dopo)

Cosa vorremmo chiedere al Tier1: 2 server dedicati, che possano essere anche VM con xrootd (con 50TB di disco anche sottratto alle pledges)

- Come detto, le configurazioni andranno aggiustate man mano quindi non mi aspetto di partire con un setup standard



Perchè ci interessa (prossimo step)

Tutto questo sistema è funzionale all' attività di R&D sulle infrastrutture di analisi (ultimo miglio) e valutarne le prestazioni.

Stiamo investigando un approccio interattivo (che aiuti e stimoli anche l'adozione dell'ecosistema python). In particolare vogliamo cercare di:


- Minimizzare l'uso della GRID per questa fase del data processing (latency)
- Massimizzare il throughput, cosa che ci interessa tanto più quanto più usiamo i NanoAOD (Run3 e HL-LHC)

Vorremmo/dovremmo poi coinvolgere ricercatori che facciano attività vera...

Dove siamo

Abbiamo varie idee, ma anche alcuni prototipi pronti ad esser integrati per testare il sistema di cache descritto.

Cache@I1_CNAF



Gli scenari che vogliamo esplorare sono sia quello di “singola macchina” che quello distribuito per fare scale out

- Scale out su risorse “locali” e veloci

Schema dell'architettura che stiamo implementando

Infine... integrazione con "DataLake"

Qui collassano tante attività che portate avanti in vari contesti

- ESCAPE
- INFN-Cloud
- ..

NOTA: tanti contributi (tanto CNAF) su molti aspetti

