

Computing model and data handling ATLAS-CMS

Simone CAMPANA
(ATLAS CERN),

Daniele SPIGA
(CMS CERN - Perugia)

Quinto Workshop italiano sulla fisica
p-p ad LHC


Perugia, 31 Gennaio 2008

Il Computing Model di ATLAS e CMS

Modello di calcolo gerarchico multi-Tier.

Architettura basata su una infrastruttura distribuita di risorse, servizi e strumenti Grid.

ATLAS



Tier-0 (CERN)

- Archiviazione dei RAW data e distribuzione ai Tier1
- Prompt Reconstruction e 1st pass calibration
- Distribuzione output ricostruzione ai Tier-1: ESD, AOD e TAG

Tier-1 (10)


- Archiviazione di un subset di RAW data
- Copia degli ESD di un altro (altri) Tier-1
- Reprocessing dei propri RAW data
- Distribuzione AOD ai Tier-2
- Archivio dati MC prodotti nei Tier-2

Tier-2

- Simulazione Monte Carlo
- Analisi (Single User e Group Analysis)

Modello a cloud: ad ogni Tier-1 sono associati alcuni Tier-2 (spesso in base a considerazioni geografiche).

CMS



➤ TO

Ricezione dati dal DAQ
Prompt reconstruction
Archiviazione RAW data e
distribuzione ai T1's

➤ **CAF** (CERN Analysis Facility for CMS)
Accesso ai RAW dataset
Finalizzata alle attività "latency-critical"
(diagnostica del rivelatore, trigger performances,
definizione costanti Al/Ca, Hot analysis)

CMS

➤ T1

Riprocessamento dati (later pass reco, AOD, Skimming)

Archiviazione Dati (Reali+MC custodial)

Distribuzione dati (serve dati ai T2 per l'analisi)


➤ T2

User Analysis

Produzione eventi MC


~20% delle risorse
Sono allocate al CERN,
40% ai T1 e 40% ai
T2.

Modello basato
sullo sviluppo di
strumenti per rendere
trasparente l'accesso
alle risorse.




Data Model ATLAS-CMS

Nelle varie fasi di ricostruzione e analisi ATLAS e CMS utilizzano diversi formati di dati:



Distribuzione Dei Dati ATLAS-CMS



- Dati originali al Tier0
- Replica completa nell'insieme dei Tier-1

- Gli ESD vengono esportati associati ai RAW in 2 copie nell'insieme dei T1
Frazioni a richiesta nei Tier-2
- I RECO vengono esportati associati ai RAW in 1 copia nell'insieme dei T1

- Una copia completa in ogni Tier-1
- Replicati parzialmente nei Tier-2 (~1/3 - 1/4 in ciascun Tier-2):
- Una copia completa in ogni T1 e replicati parzialmente ai T2

- DPD dei gruppi di analisi prodotti nei Tier1
- repliche nei Tier-2 e Tier-3
- In fase di definizione le procedure di produzione

Organizzazione e trasferimento Dati in ATLAS

- Il sistema di Distributed Data Management (DDM) implementa la funzionalità richieste dal computing model per il trasferimento dati
 - Distribuzione di raw e reconstructed data (reali e simulati) tra i vari Tier
- I dati di ATLAS sono organizzati in datasets
 - **Cataloghi di dataset centrali, suddivisi in vari DB**
 - Dataset Repository, Dataset Content Catalog, Dataset Location Catalog, Dataset Subscription Catalog
 - **Cataloghi di file distribuiti (locali)**
 - | mapping nome logico □ nome fisico: LFC (LCG File Catalog) al Tier1
- **Trasferimento dei file attraverso il Sistema di Sottoscrizione:**
 - T0 □ T1 e T1 □ T1 (inter clouds)
 - T1 □ T2 e T2 □ T1 (intra cloud)

Attività trasferimento dati

- **Functional Test:** simulazione del data flow previsto dal CM a basso rate
 - Trasferimenti T0 □ T1 e di seguito T1 □ T2 della cloud secondo lo share previsto dal Computing Model
 - Trasferimenti T1 □ T1 dei dati riprocessati
 - Studio dell'efficienza dei trasferimenti in termini di numero di dataset replicati correttamente e velocità di arrivo dei file, numero di retry
 - Test sporadici. A breve test regolari e risultati riportati nel site Reliability e Availability di WLCG
- **T0 Throughput exercise:** mantenere con stabilità i rate di trasferimento tra il CERN e le clouds previsti dal Computing Model:
 - T0 □ ©T1 = 1 GB/s
 - | T0 □ CNAF = 100 MB/s, 2/3 su disco e 1/3 su nastro
- **Run di cosmici M5**
 - Trasferimento dei dati (RAW e ESD) al CNAF e nei Tier2 secondo le percentuali previste dal Computing Model

Functional Test Ottobre 2007

Trasferimenti Tier-1 □ Tier-1

	ASGC	BNL	CNAF	FZK	LYON	NDGF	PIC	RAL	SARA	TRIUMF
ASGC		Red	Red	Red	Red	Green	Red	Red	Red	Red
BNL	Red		Green	Light Green	Green	Green	Red	Green	Green	Light Green
CNAF	Green	Green		Light Green	Green	Green	Green	Red	Light Green	Light Green
FZK	Red	Green	Green		Green	Green	Green	Light Green	Green	Green
LYON	Yellow	Yellow	Yellow	Yellow		Yellow	Green	Light Green	Red	Light Green
NDGF	Red							Green		Light Green
PIC	Yellow	Red	Green	Light Green	Green	Green		Green	Green	Light Green
RAL	Red	Yellow	Green	Green	Green	Green	Green		Light Green	Light Green
SARA	Red	Green	Green	Light Green	Green	Green	Green	Green		Light Green
TRIUMF	Yellow	Green	Green	Light Green	Green	Green	Green	Red	Green	

Trasferimenti CERN □ Tier-1s

	ASGC	BNL	CNAF	FZK	LYON	NDGF	PIC	RAL	SARA	TRIUMF
CERN	Green	Green	Light Green	Green	Yellow	Green	Green	Green	Green	Green


100% , 90+% , 50% , less than 50% , of data transferred within 24h

Throughput exercise Ottobre 2007


- Throughput al 100% MoU
 - Come se la macchina operasse 24h/day ~ 1 GB/sec
- Operazioni completamente automatizzate senza intervento
- Corretto share tra dati da inviare su tape (tipo RAW) e su disco (tipo AOD e ESD)

Obiettivo raggiunto !


Rate di ~ 1.2 GB/sec per un periodo prolungato con un set incompleto di Tier-1



Throughput MB/s



Data transferred GB



Organizzazione e trasferimento Dati in CMS

- I Dati sono organizzati in files ($O(10^6)$ files/year)
- I files sono raccolti in blocks per ragioni di data management (10^3 Fileblocks/year)
- I blocks sono raggruppati in Datasets 0.1 -> 1TB (physics driven definition)

La catalogazione dei dati avviene attraverso il Dataset Bookkeeping System (DBS):
fornisce le seguenti funzionalità:

- **Data definition:** dataset definition, runs, provenance, etc..
- **Data discovery:** quali dati esistono e come sono organizzati (files/fileblocks)
- **Data location:** dove sono i dati
- (per dati privati e pubblici)

Physics Experiment Data Export (PhEDEx)

- Gestisce in maniera affidabile il trasferimento dei dati tra i siti, usando i servizi Grid di file and storage management.
- Tecnicamente basato su agenti software che runnano autonomamente nei siti scambiando informazioni attraverso un database centrale (Transfer Management DB TMDB).
- I dati ai T2 vengono richiesti dai gruppi di fisica o singoli (chiunque può sottomettere una richiesta)

<https://cmsdoc.cern.ch:8443/cms/aprom/phedex/prod/Request::Create?view=global>

CMS LoadTest

- ❑ I siti sono pronti per il trasferimento dei dati?
- ❑ Il sistema di trasferimento dati di CMS è adeguato?


✓ PhEDEx è in produzione dal 2004

✓ Molta esperienza fin dal 2004
(CMS-specific e
WLCG-Service challenges)

✓ PhEDEx in continuo test
di trasferimento..


Dal 2007 è iniziato LoadTest...

- ❑ CERN -T1, T1-CERN (14 links)
- ❑ T1-T1 crosslinks (42 links)
- ❑ T1 to T2 downlinks (360 links)
- ❑ T2 to T1 uplinks (360 links)




Sistema di Produzione Monte Carlo in ATLAS

- Risorse di ATLAS distribuite su 3 Grid
 - EGEE ~3000 CPU, ~360 TB disk
 - NDGF ~500 CPU, ~60 TB disk
 - OSG ~2000 CPU, ~390 TB disk
- Il sistema di Produzione (Prodsys) di ATLAS e' in grado di gestire job di produzione sulle 3 griglie
 - Jobs definiti in un database centrale (ProdDB).
 - L' agente "Supervisor" la sottomissione, monitoring e validazione dei job sulle 3 griglie
 - Supervisor e' Grid-Neutral
 - L' interfaccia con il grid middleware e' implementata dagli "Executor"
 - Il movimento dei dati avviene tramite DDM.
- Evoluzione del Sistema di Produzione verso un unico executor per OSG e EGEE
 - Due scelte di base: la tecnologia dei job pilota di Panda e il Local File Catalog di LCG




Produzione Monte Carlo 2007 in ATLAS




- 50M+ eventi simulati per CSC12
 - >300 TB di MC data su disco
 - Job scaling come previsto nel 2005
- Target: 120M nuovi eventi entro aprile 2008 (FDR2)
- Attualmente 1 M ev/giorno, rate limitato dalle necessità e disponibilità di storage

- Ragionevole efficienza in termini di WallClockTime (>90% in media)
- Problemi residui:
 - Data Management (~40%)
 - ATLAS application (~40%)
 - Configurazione siti (~20%)
- Efficienza in termini di # jobs ancora non soddisfacente (<70%)
 - Sistema "Pilot Jobs" dovrebbe aiutare in questo




Overview della Produzione MC 2007

Number of Tasks




waittime Days Successful Jobs Since Dec 2006




Produzione CSC nei siti INFN

- ATLAS sfrutta risorse tutte le risorse di CPU accessibili
 - CNAF (T1)
 - T2 (Milano, Roma1 e Napoli) e Proto-T2 (Frascati) di ATLAS
 - T2 di altri esperimenti
 - Risorse condivise di INFN GRID



Sistema di Produzione Montecarlo in CMS

Strumento unico per la produzione dati MC, Skimming, riprocessamento e ricostruzione al Tier 0



- Gestisce le richieste
- Assegna lavoro al PA quando lo richiede
- Traccia il completamento del task


- Richiede lavoro
- Converte lavoro in jobs
- Crea, sottomette, traccia jobs
- Gestisce il merge, errori, risottomette, etc..

- Supporto per differenti Grid/batch Middleware

Produzione Monte Carlo 2007 a CMS



Cumulative Events Written (Merge)

364 Days from 2007-01-01 to 2007-12-31 UTC





ProdAgent Merge Events Written by Site (Sum: 1672593869 Events)

52 Weeks from 2007/00 to 2007/52 UTC



Jobs by Exit Code

363 Days from 2007-01-01 to 2007-12-30 UTC



Maximum: 106663.00 Jobs, Minimum: 4.00 Jobs, Average: 17042.44 Jobs, Current: 24067.00 Jobs

- Raggiunto un rate > 20Kjobs/day
- ~50% della produzione su OSG
- ~75% efficienza comprese Grid failures

Analisi Distribuita in ATLAS

- L' Analysis Model si basa sul principio che i job devono girare dove risiedono i dati
 - Full set di AOD e DPD presenti su disco in tutti i T1 e 1/3 dei T2
 - 2 copie del full set di ESD su disco, suddivise tra i T1
 - | Frazione minima anche ad alcuni T2
 - RAW data solo su nastro, 10% anche su disco suddivisa tra vari T1
 - Selezione degli eventi da TAG
 - Supporta backward navigation agli eventi (RAW, ESD, AOD)
 - Procedura di selezione molto veloce
 - Determinazione dei siti dove i dati sono memorizzati
 - Invio in questi siti (tramite i tool di Analisi Distribuita) dei jobs e recupero degli output: DPD e logfile
- Tool di Analisi Distribuita (job submission):
 - GANGA in EGEE
 - Pathena in OSG

GANGA

- Framework per configurazione, sottomissione, Monitoring dei Job
- Le applicazioni possono essere sottomesse, in modo assolutamente trasparente, attraverso vari tipi di risorse
 - **Macchine locali (test, debugging dell' applicazione)**
 - **Sistemi Batch (LSF, PBS, CONDOR)**
 - **Grid**
- Il giudizio obiettivo sulle performance di GANGA è complicata dalla forte dipendenza dal funzionamento di altri sistemi:
 - **DDM: i dataset non sono completamente replicati nei siti**
 - **Alta efficienza se i dataset sono completi**
 - **La replica non completa è il problema più serio**
 - **Configurazione dei siti: i job falliscono per problemi locali**
 - **comprende problemi (anche temporanei) di hardware**

Analisi Distribuita: Pathena

- **Package integrato in Athena**
 - si usa in modo del tutto simile, molto facile da usare !
- **Stesso workload usato per le produzioni ATLAS: PANDA**
 - Output registrato su catalogo in DQ2
 - bookkeeping, monitoring, status, facile risottomissione dei job , notifica via email
 - Interfaccia Web molto user friendly.
- **Giudizio degli utenti:**
 - "Not much comments here. PAtHena is the closest thing to the user dream"
 - Bisogna solo scegliere il nome del dataset di input e il dataset di output
 - Job, in media, hanno successo con un' efficienza molto alta
- **Pero'...**
 - PAtHena funziona perfettamente a BNL dove sono replicati (quasi) totalmente tutti gli AOD (BNL e' un super Tier-1)
 - E' veramente un sistema di analisi distribuita?
 - E' altrettanto possibile runnare PAtHena in siti con distribuzioni incomplete dei dati?
 - E' un modello scalabile con il numero degli utenti?
 - Issue di sicurezza da chiarire

- Fino a luglio (tabella) problemi di replicazione dati in IT
 - DDM e problemi allo storage
- Ora, "disk space crisis"
 - Meno del 20% di AOD al CNAF, ma ragionevolmente selezionati

	ASGC	BNL	CERN	CNAF	FZK	LYON	NG	PIC	RAL	SARA	TRIUMF	%
ASGC												80
BNL												92
CERN												45
CNAF												21
FZK												84
LYON												85
NG												82
PIC												X
RAL												25
NIKHEF												36
TRIUMF												36

Analisi Dati Distribuita in CMS

- Data driven Analysis Model
 - Dati distribuiti nei siti
 - Sw di CMS precedentemente installato
- Dal punto di vista dell'utente:
 - Sviluppo e test del codice localmente su piccoli campioni di eventi
 - Selezione/ricerca del dataset e Sottomissione dei jobs alla Grid
 - Ritiro degli outputs prodotti...
- CMS ha sviluppato un unico strumento per l'utilizzo dell'infrastruttura in fase di analisi:
 - CRAB: CMS Remote Analysis Builder

CRAB

- Rende trasparente l'utilizzo delle risorse di CMS per le attività "private" dell'utente:

- Automatizza la data discovery, la preparazione, configurazione dei jobs, sottomissione...
- Completamente interfacciato a OSG/LCG/risorse Locali (LSF,CAF)
- Supporta la sottomissione

attraverso un servizio 24X7

Gestione automatica

degli errori, del ritiro degli


Output...

(automatizza tutto il workflow


riducendo il carico dello user

umentando l'efficienza)

- In produzione da ~3 anni




User Community nel 2007







○ Numero di utenti per settimana

○ Numero totale di utenti






CMS Analysis jobs 2007



Commissioning dei siti per l'analisi

- **JobRobot: generatore di fake-analysis-jobs**
 - Implementato nel 2005/2006 come un "semplice wrapper" attorno a CRAB
 - Sottomette jobs a tutti I siti di CMS
 - Accesso via web alle statistiche ed ai log files.
- **GangaRobot: generatore di fake-analysis-jobs**



Summary

- ATLAS e CMS hanno adottato un modello di computing distribuito basato sulla tecnologia di Grid
- Stanno migliorando la qualità dei tools facendo commissioning di risorse, servizi e strumenti a larga scala con complessi esercizi di computing
- Next steps: see Simone slides....