



# Modèle de calcul d'ATLAS et Exercices en vraie grandeur de la grille WLCG par l'expérience ATLAS

S. Jézéquel



## Journées Informatiques 06



- ▶ **Expérience ATLAS auprès du LHC**
- ▶ **Modèle de calcul ATLAS (théorie)**
  - ▶ **Taux de production de données**
  - ▶ **Distribution et stockage des données sur la grille**
  - ▶ **Analyse des données**
- ▶ **Manière effective de travailler en Septembre 2006**
  - ▶ **Installation du soft et réplication des données**
  - ▶ **Simulation**
  - ▶ **Analyse (*Collaboration avec C. Bourdarios (LAL)*)**




## Participation à ATLAS/Grille


- ◆ Depuis seulement 18 mois
- ◆ Bénéficie de l'aide active:
  - ◆ Du support Grille du LAPP
  - ◆ Du personnel du CCIN2P3

Outils de grille ont beaucoup changé

(SRM, FTS, LFC, ...) : Pas dans une phase stable



Risque de stigmatiser les problèmes actuels



**Une des 4 expériences LHC auprès du CERN (Genève)  
Collisions proton-proton de 14 TeV à 40 MHz**

**Phase de commissioning de l'accélérateur et détecteur en 2007  
Démarrage pour la physique : courant 2008**

**Montée en charge dans les années 2009/2010**



**Première version: Publiée mi-2005 (TDR)**

**Premiers correctifs: courant 2006**

**Devra encore s'adapter aux réalités**

## **Partie Grille :**

**Utilisation autant que possible**

**des outils standards LCG (SRM,LFC,FTS,...)**

**→ doivent être complètement opérationnels**

**(faible taux d'erreur en production,**

**monitoring des erreurs)**


**sinon ...**



# LCG Service Model

## Tier-0 - Lieu de production des données

- Acquisition et premier traitement
- Stockage à long terme (backup des T1)
- **Distribution vers les centres Tier-1**



Canada – Triumf (Vancouver)  
France – IN2P3 (Lyon)  
Germany – Karlsruhe  
Italy – CNAF (Bologna)  
Netherlands – NIKHEF/SARA (Amsterdam)  
Nordic countries – distributed Tier-1

Spain – PIC (Barcelona)  
Taiwan – Academia Sinica (Taipei)  
UK – CLRC (Oxford)  
US – FermiLab (Illinois)  
– Brookhaven (NY)

## Tier-2 - ~100 centres dans ~40 pays

- Simulation
- Analyse – batch et interactif
- **Reception des données du Tier-1 associé**

## Tier-1 - "online" avec la prise de données → fonctionnel 24/7

- Stockage de Masse -  
→ Services grille
- **Tous les re-processings**
- Analyses de beaucoup de données
- Support national et régional

# Données réelles: Tier-0



- ◆ **Après filtrage en ligne,**

- ◆ événements bruts (RAW) : 200 Hz

- ◆ Taille : 1,6 Mo/evt

➡ 1 Po/an (1 an= $4 \cdot 10^6$ s) (2008)      3 Po/an (1 an= $10^7$ s) (2010)

- ◆ **Première reconstruction des données au CERN:**

- ◆ **ESD (0,5 Mo/evt)**

Réduction des données ➡ **AOD (0,1 Mo/evt)**

(utilisées par les physiciens pour leur analyse)

**Total : 2-5 Po/an**

- ◆ **Transferts des données dans les T1**

- ◆ **Pas de traitement ultérieur au CERN**

**mais archivage/backup long terme**



**T1 recoit les données reconstruite en ligne (~13%)  
(~80 Mo/s ATLAS/LYON)**

**Rôle :**

**Reconstructions ultérieures (~3/an)  
à partir de sa copie de données RAW  
Production de nouvelles ESD/AOD**

**Stockage de toutes les AODs (échange d'AOD entre T1)  
Distribution des AODs dans les T2**

**Redondance du stockage des ESDs  
entre paires de T1 (CCIN2P3-BNL)**

**Etat de la validation**

- **Transfert ~OK en phase de test**
- **Reprocessing pas encore tester**

# Données réelles: Tier2

**T2 recoit une copie des AODs ( $N \times 20$  Mo/s T1  $\rightarrow$  tous les T2)  
(Centre de Calcul Locaux)**

**Rôle :**

**Mise à disposition des AODs pour l'analyse des données  
(= Ferme d'analyse)**


**Validation:**

- **Transfert commence à marcher sur courte période**
- **Activité d'analyse pas possible sur SE DPM avec les outils Grille  
(accès uniquement par copie sur le disque local)**




- Seule activité opérationnelle et possible à ce jour
- Produites dans les T2/T3 (et T1 actuellement)
- Centralisées dans le T1 (lieu de stockage de masse)
- Réplication des AODs vers les autres T1 (3 To)

# Réplication/enregistrement data



**DDM : Outil ATLAS pour organiser les transferts**



- **BEIJING**
- **TOKYO**



# Utilisation actuelle de la grille dans ATLAS



# Premier commentaire sur la grille LCG

**Quand on utilise la grille quotidiennement sur ATLAS,  
il ne se passe pas une journée  
sans un nouveau problème**

- ♦ **Implementation de la grille (certificats,...)**
- ♦ **Interface avec les infrastructures matériels**
- ♦ **Multiplicité des sites (85% \*\* 10 sites = 20%)**

**Il faut et on peut avancer  
mais demande beaucoup d'efforts !!!!**

**Avoir des contacts directs avec les sites  
(Si pas de contact, on passe par GGUS)**

**Essayer de se restreindre à quelques sites**

**Au niveau T1,  
collaboration poussée entre CC, CERN et BNL  
(Sites pilotes pour l'analyse de données  
recommandés par ATLAS)**

**Avoir des réunions régulières avec les T2/T3  
du nuage français**



# Distribution du software ATLAS



- ◆ ~100 sites pour ATLAS
- ◆ Installation automatisée/centralisée
  - ◆ Marche dans 50% des cas (sites stables)
  - ◆ Origines d'erreurs
    - ◆ Sites en évolution (changement de SE, d'OS,...)
    - ◆ Zones disques affectées au stockage de softs pleine


Besoin de contact direct

entre le responsable du site et ATLAS




# Réplication/Publication des données

- ▶ **Passage obligé**
- ▶ **Besoin d'outils performants et robustes**



**OK dans cadre restreint**

**FR : Premier 'nuage'  
opérationnel  
de la grille EGEE**





# Réplication/Publication des données

- ▶ Dans un environnement non dédié :
  - ▶ Surcharge du catalogue LFC
  - ▶ 10-20% d'erreur sur les transferts FTS  
(transfert multi-site simultanés)
  - ▶ Non optimisation de DDM

Travail en cours  
mais  
déjà en phase de production dans ATLAS



- ◆ **Soft ATLAS : Athena (aucune interaction directe avec la Grille)**
- ◆ **Enchaînement des actions:**
  - ◆ **S'assure que les données sont accessibles localement sinon utilise les commandes grilles pour les repliquer localement**
  - ◆ **Construit le joboption en utilisant les infos des catalogues LFC**
  - ◆ **Tourne un job Athena en accédant directement aux données ou en les copiant sur le disque local**
  - ◆ **Copie les fichiers en sortie localement ou sur un SE grille**



**Partie de la chaine d'analyse tirant le meilleur profit de la Grille avec un minimum de développement**

- ♦ **Besoin d'avoir un CPU disponible**
- ♦ **Un seul fichier en entrée**
- ♦ **Peu d'accès en lecture/écriture**
- ♦ **Temps de soumission  $\ll$  Temps d'exécution**
- ♦ **Ne nécessite que qq experts pour lancer les jobs**

**Point critique :**


**Accès aux données au cours de la simulation ou après**



# Simulation: Implémentation mi-2005

Fichier  
100 evt  
120 Mo

Fichier  
100 evt  
10 Mo



**Simulation**

**Reconstruction**

Trop de petits fichiers : Surcharge des catalogues LFC

Fichiers dispersés sur les sites :


Maximise la probabilité d'indisponibilité

# Simulation: Implémentation fin-2005



Fichier  
100 evt  
120 Mo

Fichier  
1000 evt  
100 Mo




**Simulation**

**Reconstruction**

Fichiers RAW dispersés sur les sites :

Maximise la probabilité d'indisponibilité

# Simulation: Implémentation 2006



**Simulation**

**Reconstruction**

Production d'un type de données


sous la responsabilité d'un 'nuage'

**Maximise l'utilisation du CPU**

**Ne permet pas réallocation de charge hors d'un nuage**

# Vitesse de production

- ◆ **Encore fortement instable**
- ◆ **En deçà des attentes d'ATLAS (facteur 3)**



## Prochaines évolutions:

- **Etiqueter un job de production centralisée par un rôle VOMS**
- **Donner la priorité dans les queues des sites à ces jobs**

# Analyse des données

En collaboration avec C. Bourdarios



♦ **Travail de tous les physiciens**

**(ca doit marcher comme sur la doc)**

**Commandes grilles de bas niveau inconnues  
et/ou limitations grille/infrastructure**

**➡ Bonne fiabilité et stabilité avant diffusion**



## ◆ En 2006:

- ◆ Travail sur des données simulées avec l'équivalent de qq jours de données
- ◆ Utilisent les répliquions des données locales (commencent à se former aux outils de répliquions)
- ◆ Tourne les jobs analyses en interactif ou avec qq batchs BQS/LSF

# Analyse des données:Prospective



**Analyse avec infrastructure Grille :**  
**Utile lorsque beaucoup de données seront disponibles**

**En phase d'évaluation et debugging des outils**

**Préalable: nécessite de rassembler sur un/plusieurs sites  
tous les fichiers d'un même job**

**2 interfaces utilisateurs sur le marché:**

- **Panda (made in BNL)**  
Ne tournait qu'à BNL jusqu'à récemment mais avec succès  
Volonté de le porter sur LCG (1 job a déjà tourné à Lyon)
- **Ganga (made in Europe: LHCb/ATLAS)**  
Commence juste à être opérationnel dans ATLAS  
CCIN2P3 est un des sites de validation



# Analyse des données:Prospective(2)

Quid de l'analyse sur les T2 avec SE DPM?

- **Envoyer des jobs sur ces sites : OK**
- **Possibilité d'écrire son script pour:  
Copies des fichiers sur disque scratch local  
Turner Athena**
- **Pas encore d'accès direct aux fichiers par rfio  
(annoncé pour Octobre)**
- **Important d'aboutir pour avoir un intérêt local à faire  
fonctionner un T2/T3**



# Analyse des données:Prospective(3)

**Pas encore d'implémentation d'algorithme sur choix des sites au delà de la seule disponibilité de CPU**

## Exemples:

- **Disponibilité des données (bientôt)**
- **Disponibilité effective du site**
- **Vitesse d'accès aux données à un instant  $t$**
- **Répartition de la charge entre sites (>1000 jobs)**

**Rapidité de soumission de job (Resource Broker)**



- ▶ **Commence la validation concrète du modèle de calcul**
- ▶ **Mise en place pas finie des outils Grille indispensables**
- ▶ **Point de passage obligé : outil de réplique performant et robuste (ATLAS/Grille)**
- ▶ **Simulation sur la grille en cours de stabilisation**
- ▶ **Démarrage de la validation de l'analyse sur la grille (job Grille/ accès aux données sur un SE)**

Beaucoup de travail encore en perspective

mais effort français visible dans ATLAS