



Enabling Grids for E-scienceE

Gestion des données

David Bouvet

IN2P3-CC

Annecy - 27/09/2007

www.eu-egee.org



Information Society
and Media



- **Commandes de bases**
 - copier, lister, répliquer, effacer les données
 - lcg-infosites
- **Gestion à travers un job**
- **Catalogue LFC**

- **Replica-manager (RM) est le principal outil**
 - **LCG File Catalog (LFC)** garde la trace de la localisation des diverses copies des fichiers grille
 - le transfert de données utilise surtout *gsiftp*
 - comme le bon vieux FTP, et utilise l'authentification grille
 - pas de mot de passe !
 - peut aussi utiliser des flots multiples pour un transfert plus rapide
 - RM couvre l'interaction entre *gsiftp* et le LFC pour faciliter l'instanciation, l'enregistrement et la réplication des données grille

- **Resource Broker**
 - peut envoyer (un petit ensemble) de données aux/depuis les jobs
 - peut utiliser le LFC pour trouver vos données et les envoyer à votre job, si vos données sont dans le LFC et que vous le spécifiez au RB

- **Mettre des données sur la grille :**
 - Mettre le fichier /home/myhome/toto (de l'ordinateur local) sur le *Storage Element* leSEchoisi01.in2p3.fr et l'enregistrer avec le *nom de fichier logique* macopie.test
 - **lcg-cr** -d leSEchoisi.in2p3.fr -l \
lfn:/grid/vo.lapp.in2p3.fr/macopie.test \
--vo vo.lapp.in2p3.fr file:/home/myhome/toto
- **Storage Element** – machine accessible par la grille pour le stockage de données
- **Logical File Name** – nom de fichier symbolique avec lequel vous pouvez faire référence à un fichier grille sans préciser sa localisation physique actuelle
- **La commande ci-dessus retourne le “GUID” :**
 - guid:76373236-b4c7-11d8-bb5e-eba42b5000d0
- **Les GUID sont permanents, les LFN non !**

- Copier des données grille en local :
 - **lcg-cp** --vo vo.lapp.in2p3.fr
lfn:/grid/vo.lapp.in2p3.fr/macopie.test
file:///home/myhome/macopielocale
- La commande **lcg-cp** peut être utilisée pour copier des données locales sur un SE.
Il n'est pas recommandé de l'utiliser de cette manière car il n'y a pas d'enregistrement dans le catalogue LFC.

- **Trouvez vos données : la méthode listReplicas (lr)**

- **lcg-lr** --vo vo.lapp.in2p3.fr
lfn:/grid/vo.lapp.in2p3.fr/macopie.test
via LFN
 - sfn://leSEchoisi.in2p3.fr/grid/vo.lapp.in2p3.fr/tutorial/data/generated/2004-11-10/file7115df45-b4c7-11d8-bb5e-eba42b5000d0
- lcg-lr --vo vo.lapp.in2p3.fr \ # via GUID
guid:76373236-b4c7-11d8-bb5e-eba42b5000d0
 - sfn://leSEchoisi.in2p3.fr/grid/vo.lapp.in2p3.fr/tutorial/data/generated/2004-11-10/file7115df45-b4c7-11d8-bb5e-eba42b5000d0

- “*replicas*” car quelqu’un (ou un programme) peut faire une copie sur un SE différent.
Les LFN et GUID font référence à toutes les copies

- Vous pouvez dupliquer vos données sur d'autres SE à partir du LFN du fichier :

```
– lcg-rep --vo vo.lapp.in2p3.fr
  lfn:/grid/vo.lapp.in2p3.fr/macopie.test -d
  autreSEchoisi.in2p3.fr
```

- Si vous listez ces données avec la méthode `listReplicas`, vous trouvez une nouvelle liste :

```
– sfn://leSEchoisi.in2p3.fr/grid/vo.lapp.in2p3.fr/tutorial/data/generated/2004-11-10/file7115df45-b4c7-11d8-bb5e-eba42b5000d0
  sfn://autreSEchoisi.in2p3.fr/grid/vo.lapp.in2p3.fr/tutorial/data/generated/2004-11-10/file3498dg93-h3b6-38s2-kf7d-ksr38h8379q7
```

- Pour effacer les données d'un SE à partir du LFN :
 - `lcg-del --vo vo.lapp.in2p3.fr -s autreSE.in2p3.fr lfn:/grid/vo.lapp.in2p3.fr/macopie.test`
- Il faut spécifier le *hostname* du SE car en cas de *replicas*, la commande ne sait pas quel fichier effacer.
- Pour effacer tous les *replicas* d'un fichier, il faut rajouter **l'option -a**
 - Cette option est aussi nécessaire lorsqu'il n'y a pas de *replica*
- Le catalogue LFC est mis à jour

- Trouver l'information concernant le LFC ou le "DMS" (*Data Management System*)

- comment connaît-on que `leSEchoisi.in2p3.fr` était un SE ?

- **lcg-infosites** --vo atlas se

```

*****
These are the related data for atlas: (in terms of SE)
*****
Avail Space(Kb) Used Space(Kb)                SEs
-----
725228544      5741568                clr1cgse01.in2p3.fr
190257628      38750756               clr1cgse02.in2p3.fr

```

- Beaucoup d'autres informations peuvent être affichées
 - emplacements des composants du LFC
 - emplacements de toutes les ressources

- Commandes de bases
- **Gestion à travers un job**
- **Catalogue LFC**

- **Vous pouvez définir votre job pour récupérer les données**
 - le job génère des données dans le répertoire de travail du WN
 - à la fin du job, les données sont placées dans l'espace de stockage temporaire du RB
 - vous les récupérez via `edg-job-get-output`
- **Éléments clés :**
 - vous devez connaître les noms des fichiers que vous souhaitez récupérer
 - **`OutputSandbox = {"higgs.root", "graviton.HDF"};`**
 - méthode non destinée pour de gros fichiers (> centaine MB)
 - espace de stockage temporaire limité sur le RB

- **Votre programme génère des données dans un fichier local au WN**
- **Le programme doit connaître quel est le nom du fichier local**
- **Le programme utilise les commandes **lcg-*** pour :**
 - mettre les données sur un SE de la grille
 - enregistrer les données comme un jeu de données grille
- **Deux options utiles :**
 - sur quel SE les données doivent-elles être sauvegardées (ou même dans quel répertoire de quel SE !) ?
 - par défaut : SE “local”
 - un nom de fichier logique.
 - **par défaut : pas de LFN !**

- **L'attribut `OutputData` du JDL spécifie où les fichiers doivent aller**
 - si aucun LFN n'est précisé, le WMS en choisit un
 - si aucun SE n'est précisé, le SE le plus proche est choisi

```
OutputData = { [
  OutputFile = "toto.out" ;
  StorageElement = "adc0021.cern.ch" ;
  LogicalFileName = "lfn:/grid/gilda/theBestTotoEver" ; ],
  [
  OutputFile = "toto2.out" ;
  StorageElement = "adc0021.cern.ch" ;
  LogicalFileName = "lfn:/grid/gilda/theBestTotoEver2" ; ]
};
```

- **A la fin du job, les fichiers sont effacés du WN et enregistrés sur le SE**
- **Un fichier contenant le résultat de cette opération est créé et ajouté à l'*Output Sandbox* : `DSUpload_<unique jobstring>.out`**

- C'est facile : utiliser le champ **InputSandbox** du JDL
- Attention :
 - on ne peut pas utiliser ce champ pour de trop grand transfert (plusieurs megabytes)
 - **InputSandbox = {"input-ntuple.root", "job.sh"};**
 - InputSandbox ne peut pas contenir 2 fichiers ayant le même nom, même s'ils ont un chemin absolu différent : ils s'écraseraient l'un l'autre pendant le transfert.

- Il faut des données sur la grille == enregistrées dans le LFC
- Spécifiez les données grille au job (JDL) :
 - `InputData = "lfn:/grid/gilda/myfile.dat"`
- Le Resource Broker met des infos concernant la correspondance avec les données dans le fichier *.BrokerInfo* sur le noeud d'exécution distant
- Dans le script d'exécution de votre job, utilisez la commande *edg-brokerinfo* & les commandes *lcg-** pour avoir une copie locale du job

- Commandes de bases
- Gestion à travers un job
- **Catalogue LFC**

- **Le catalogue LFC (LCG File Catalog) présente une arborescence et des commandes façon « système de fichiers » :**
 - il est possible de lister les références, de créer une nouvelle arborescence, de faire des liens symboliques...

- **Par défaut, le catalogue utilisé est le catalogue central de la VO.**
 - `lcg-infosites --vo vo.lapp.in2p3.fr lfc`
retourne le nom du LFC central
 - `lcg-infosites --vo vo.lapp.in2p3.fr lfcLocal`
retourne la liste des catalogues locaux de la VO

- **Pour utiliser un catalogue :**
 - `export LFC_HOST=<hostname du LFC choisi>`
- **Racine de l'arborescence d'un LFC :**
 - `/grid/<nom de la VO>`
 - on peut stocker cette racine dans la variable `$LFC_HOME`
- **Lister les références :**
 - `lfc-ls /grid/vo.lapp.in2p3.fr/...`
 - `lfc-ls $LFC_HOME/...`
- **Créer une nouveau répertoire :**
 - `lfc-mkdir /grid/vo.lapp.in2p3.fr/.../<mon rep>`
- **Autres ex. de commandes :**
 - `lfc-ln, lfc-rm, lfc-getacl, lfc-setacl...`

- **Projet LCG**
 - <http://lcg.web.cern.ch/LCG/>
- **Projet EGEE**
 - <http://www.eu-egee.org/>
 - <http://www.eu-egee.org/try-the-grid> (tutorial en ligne)
- **LCG user**
 - <http://lcg.web.cern.ch/LCG/users/users.html>
- **gLite User Guide**
 - <https://edms.cern.ch/file/722398//gLite-3-UserGuide.html>
- **LCG FAQ (pas à jour mais ça aide quand même)**
 - <https://edms.cern.ch/file/495216/1/LCG-Faq.html>
- **Doc diverses sur la grille**
 - <https://gus.fzk.de/pages/docu.php>
- **User Support**
 - <http://www.ggus.org/>
pour soumettre des incidents pour la VO, pour un site...

