


Tecnologías Grid

gLite

Curso de Doctorado 2008-2009

Área de Arquitectura y Tecnología de Computadores

Universidad de Oviedo



gLite

Introducción

Introducción

- EGEE (Enabling Grids for E-sciencE)
 - ▣ Mayor infraestructura grid del mundo
 - ▣ 120 organizaciones europeas, 47 países, 68000 CPUs, 8000 usuarios, 150000 trabajos al día
- gLite
 - ▣ Middleware que da soporte a EGEE
 - ▣ Integra un conjunto de componentes para habilitar la compartición de recursos entre múltiples organizaciones
 - ▣ Se basa en otros proyectos: Globus, Condor, LCG, ...

Inicialmente la última E de EGEE significaba Europa

Introducción

Servicios gLite

Acceso

CLI

API

Seguridad

Authorization

Auditing

Authentication

Monitorización e Info.

Information & Monitoring

Auditing

Application Monitoring

Datos

Metadata Catalog

File & Replica Catalog

Accounting

Storage Element

Data Movement

Connectivity


Trabajos

Job Provenance

Package Manager

Computing Element

Workload Management



gLite

Servicios de seguridad


Servicios de seguridad

- Autenticación basada en X.509
 - ▣ Las autoridades de certificación (CA) emiten certificados a los individuos
 - ▣ Para evitar vulnerabilidades, la identificación de los individuos se realiza mediante proxies
- Un proxy
 - ▣ Puede delegarse a otro servicio
 - ▣ Puede almacenarse externamente (MyProxy)
 - ▣ Puede incluir atributos adicionales (pertenencia a organizaciones)

Servicios de seguridad

- VOMS (Virtual Organization Membership Service)
 - ▣ Los certificados no son suficientes para definir las capacidades de un usuario del grid
 - ▣ VOMS proporciona un mecanismo para añadir atributos adicionales a un proxy
 - Los atributos proporcionan capacidades adicionales

```
subject      : /C=IT/O=GILDA/OU=Personal Certificate/L=GIJON/CN=GIJON01/CN=proxy
issuer       : /C=IT/O=GILDA/OU=Personal Certificate/L=GIJON/CN=GIJON01
identity     : /C=IT/O=GILDA/OU=Personal Certificate/L=GIJON/CN=GIJON01
type         : proxy
...
=== VO gilda extension information ===
VO           : gilda
subject      : /C=IT/O=GILDA/OU=Personal Certificate/L=GIJON/CN=GIJON01
issuer       : /C=IT/O=INFN/OU=Host/L=Catania/CN=voms.ct.infn.it
attribute    : /gilda/Role=NULL/Capability=NULL
timeleft     : 11:18:08
```



gLite

Servicios de información

Servicios de información

- Objetivos de los servicios de información (IS):
 - ▣ Descubrir los recursos
 - ▣ Recopilar información del estado de los recursos
 - ▣ Proporcionar datos para gestionar la carga computacional y de datos de forma eficiente
- IS en gLite:
 - ▣ El modelo de datos se basa en el esquema GLUE (Grid Laboratory Uniform Environment)
 - ▣ La arquitectura utiliza BDII (Berkeley DB Information Index)

Servicios de información


- Esquema GLUE:
 - ▣ Especificación sobre la información que puede ser publicada acerca de un grid
 - El objetivo es describir los recursos grid y sus atributos
 - ▣ La información se expresa de diversas formas:
 - LDAP, SQL, XML, ClassAd
 - ▣ Los elementos se organizan jerárquicamente:
 - Site, Cluster, Computing Element, Storage Element, etc.
 - ▣ Ejemplos de atributos:
 - GlueCEStateTotalCPUs, GlueCEStateFreeCPUs, GlueHostMainMemoryRamSize, etc.


Servicios de información

- Sistema de información:
 - Es una evolución del Globus MDS
 - Se basa en servidores Lightweight Directory Access Protocol (LDAP)
 - Componentes:
 - GRIS (Grid Resource Information Server): recopila información sobre los recursos locales
 - BDII: recopila información proporcionada por los GRIS
 - De forma periódica (cron) la información se transfiere entre BDIIs
 - Los usuarios u otros servicios pueden consultar al BDII de más alto nivel sobre el estado de cualquier recurso del grid

Servicios de información

□ Arquitectura del sistema de información:





gLite

Servicios de gestión de datos

Servicios de gestión de datos

- Elementos de almacenamiento (SE):
 - ▣ Servicio que permite a los usuarios almacenar y acceder a información
 - SE = SRM + GridFTP + E/S
 - ▣ Protocolos de transferencia utilizados por los SE:
 - GSIFTP
 - ~GridFTP (estrictamente es un subconjunto del GridFTP)
 - GSIDCAP (GSI dCache Access Protocol)
 - Versión del protocolo dcap (nativo de dCache) que utiliza la seguridad GSI
 - RFIO/GSIRFIO (Remote File Input/Output protocol)
 - Para acceder a los archivadores de cinta

Grid de datos europeo

□ Tipos de SE:

□ CASTOR

- Consiste en un frontend que proporcionar una caché en disco a un sistema de almacenamiento masivo en cinta.
- El proceso "stager" realiza la transferencia entre el disco y la cinta

□ dCache y DPM

- Gestionan el almacenamiento distribuido en varios servidores de forma centralizada
- Los discos se combinan formando un único sistema de ficheros virtual


Todos proporciona un interfaz SRM

Grid de datos europeo

- Nombres de ficheros:
 - GUID (Grid Unique Identifier)
 - Identifica de forma univoca a un fichero
 - `guid:38ed3f60-c402-11d7-a6b0-f53ee5a37e1d`
 - LFN (Logical File Name)
 - Alias para referirse a un fichero (evita utilizar el GUID)
 - `lfn:/grid/gilda/Datos/Dato1.txt`
 - SURL (Storage URL)
 - Identifica una replica en el SE
 - `srm://srm.cern.ch/castor/cern.ch/grid/dteam/doe/file1`
 - TURL (Transport URL)
 - Punto de acceso temporal para un replica
 - `gsiftp://tbed0101.cern.ch/data/dteam/doe/file1`


Servicios de gestión de datos

□ Relaciones entre nombres de ficheros:



Servicios de gestión de datos

□ Relaciones entre nombres de ficheros (LCG-2):




Servicios de gestión de datos

- Transferencia de un fichero (LFNsrc) a un SEdest:
 - Se pregunta al RMC (Replica Metadata Catalog) por el LFNsrc
 - Responde con su GUID
 - Se pregunta al RLS (Replica Location Service) por el GUID
 - Responde con una lista de URLs
 - Se pregunta al ROS (Replica Optimization Service) por el coste de transferir de los URLs a SEdest
 - En función de la respuesta se elige el mejor URL
 - Se transfiere LFNsrc desde SURLbest a SEdest
 - Se registra el nuevo SURL en SEdest
 - Se añade un nuevo mapeo al GUID

LCG-2

Servicios de gestión de datos


□ Transferencia de un fichero (LFNsrc) a un SEdest



LCG-2


Servicios de gestión de datos

- Relaciones entre nombres de ficheros (LCG-3):



Servicios de gestión de datos

□ Arquitectura del LFC (LFN como clave primaria):



Servicios de gestión de datos

□ Interfaz del LFC:

□ Comandos lcg-* más APIs lcg_*

- Proporcionan la funcionalidad necesaria para acceder a la información y manipularla

□ Ejemplos de comandos:

- Listar el contenido de un directorio


```
$ lfc-ls /grid
```

- Copiar un fichero a un SE y registrarlo

```
$ lcg-cr -d servidoresrm.atc -l lfn:/grid/fich.dat file:$PWD/file1.txt
```

- Replicar un fichero en otro SE

```
$ lcg-rep -d servidoresrm2.atc lfn:/grid/gilda/fich.dat
```



gLite

Sistema de gestión de carga de trabajo


Sistema de gestión de carga de trabajo

- Workload Management System (WMS):
 - ▣ Conjunto de componentes responsables de la distribución de los trabajos sobre los recursos computacionales
 - ▣ Recibe trabajos de los usuarios y los dirige a los elementos de computación (CE)
 - ▣ Se encarga de realizar el matchmaking:
 - Estado de los recursos, requisitos, preferencias, etc.
 - ▣ Utiliza WMPProxy + Condor-G


Sistema de gestión de carga de trabajo

- Elemento de computación (CE):
 - Frontend a un cluster
 - El cluster es gestionado por un LRMS: Condor, LSF, PBS, SGE
 - El CE recibe trabajos del WMS y los envía al LRMS
 - El LRMS los envía un nodo de ejecución (WN)
 - Cuando el WN termina la ejecución del trabajo, el CE devuelve los resultados al WMS
 - Versiones de gatekeeper o Grid Gate (GG):
 - LCG-CE (GT2 + GSI-enabled Condor)
 - Glite-CE (GSI-enabled Condor-C)
 - Cream (en desarrollo)


Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo



Sistema de gestión de carga de trabajo



Sistema de gestión de carga de trabajo




Sistema de gestión de carga de trabajo

- Algunos componentes del WMS:
 - WMPoxy
 - Recibe peticiones de los usuarios a través del UI y las valida
 - Crea el Input Sandbox
 - WM (Workload Manager)
 - Nucleo del WMS
 - Procesa las peticiones de trabajos
 - Realiza el matchmaking
 - JC (Job Controller)
 - Prepara el fichero de envío de Condor
 - Lo envía a Condor

Sistema de gestión de carga de trabajo


- Algunos componentes del WMS:
 - Condor
 - Realiza la gestión del trabajo
 - DAGMan
 - Gestiona los trabajos con dependencias
 - LM (Log Monitor)
 - Monitoriza el log de Condor
 - Intercepta eventos sobre el estado del trabajo





gLite
job
submission
chain
v1.2
2007/06/12

User Interface

Worker Node







Sistema de gestión de carga de trabajo

□ Algunas siglas:

EGEE: Enabling Grids for EScience

VO: Virtual Organisation

JDL: Job definition Language

BDII: Berkeley Database Information Index

GRAM: Globus Resource Allocation Manager

MDS: Metadata Directory Service

GRIS: Grid Resource Information Service

GSI: Grid Security Infrastructure

GUID: Globally (Grid) Unique Identifier

IS: Information System

GAHP: Grid ASCII Helper Protocol

RGMA: Relational Grid Monitoring Architecture

GLUE: Grid Laboratory Uniform Environment

CG: Grid Gate

LRMS: Local Resource Management System

LM: Log Monitor

JC: Job Controller

LB: Logging and Bookkeeping

LB: Logging and Bookkeeping

PRS: Proxy Renewal Service

PS: Proxy Server

VOMS: Virtual Organisation Membership

RB: Resource Broker

UI: User Interface

WM: Workload Manager

WMS: Workload Management System

WN: Worker Node

CE: Computing Element

SE: Storage Element

ICE: InterfacetoCrEam