

# Архитектура и основные сервисы gLite (проект EGEE)

Н. Клопов (Петербургский Институт Ядерной  
Физики РАН)


**Middleware – в контексте Grid, это специфическое программное обеспечение, использующееся для функционирования распределенной компьютерной сети.**

**gLite: очередное поколение промежуточного программного обеспечения (ППО) проекта EGEE**

**Исходно EGEE использовал ППО своего предшественника - проекта EDG (European Data Grid). Это ППО затем было развито в пакет LCG, и именно LCG работал в инфраструктуре EGEE на ранней стадии проекта.**

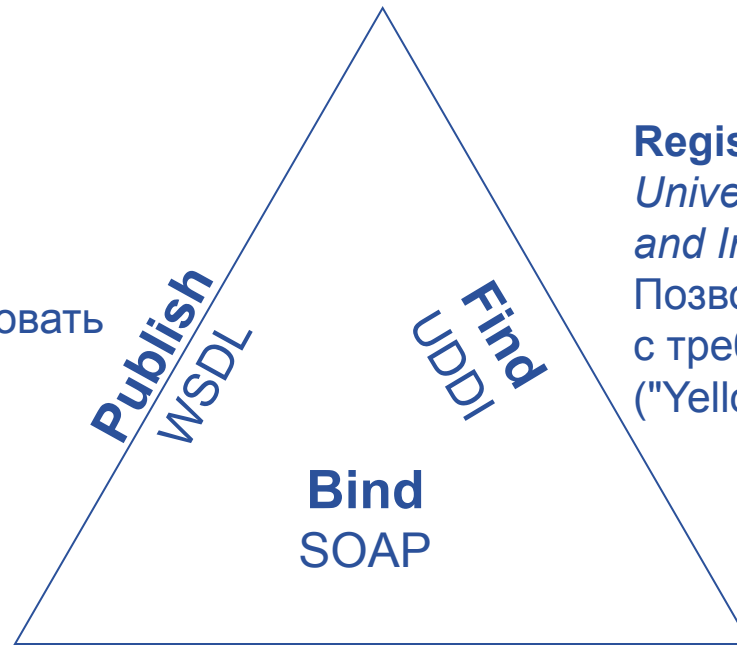
**Параллельно в EGEE были выполнены работы по модернизации большей части исходного пакета, и был создан новый продукт – gLite, который сейчас устанавливается в инфраструктуру**

- EGEE middleware is supposed to be developed following Service Oriented Architecture (SOA ) model. A service is a function which is well-defined, self-contained and does not depend on the context or state of other services.
- The services communicate with each other through well-defined interfaces and protocols (data passing or coordination of activities)
- Based on WEB service application that exposes its features using standard Internet protocol. WEB services interact by exchanging messages using Simple Object Access Protocol (SOAP) standard.
- Web Service Definition Language (WSDL) is used to specify the interface a service exposes.



- Service Oriented Architecture (SOA) определяет, как несколько независимых, распределенных процессов должны взаимодействовать при выполнении общей задачи (CORBA, DCOM).

## Service Discovery



### Interface

*Web Services Description Language (WSDL)*

Определяет как использовать Сервис

### Registry

*Universal Description, Discovery and Integration (UDDI)*

Позволяет определить адрес сервиса с требуемой функциональностью ("Yellow Pages")

Service Provider

Service Requestor

- Веб-сервис – программная система, идентифицируемая URI, интерфейс внешнего доступа которой and bindings описываются при помощи WSDL. Другие программные системы могут обнаруживать и взаимодействовать с Веб-сервисами в соответствии с их описанием на основе использования XML-сообщений посредством протокола SOAP.

## ReplicaManager::getAccessCost (LFN[], CE)

<SOAP-ENV: Envelope

.....

<SOAP-ENV:Header> ..... </SOAP-ENV:Header>

<SOAP-ENV:Body>

<m:getAccessCost xmlns:ns1=<http://datagrid:ReplicaManager>

<LFN xsi:type="SOAP-ENC:ARRAY" SOAP-ENC:ArrayType="xsd:string[2]">

<lfn> host1.cern.ch/path1/file1</lfn>

<lfn> host1.cern.ch/path2/file2</lfn> </LFN>

<CE xsi:type="xsd:string">myComputeElement </CE>

</m:getAccessCost>

</SOAP-ENV:Body>

</SOAP-ENV: Envelope>

## Return message:

<SOAP-ENV: Envelope

.....

<SOAP-ENV:Body>

<m:getAccessCostResponse

xmlns:ns1=<http://datagrid:ReplicaManager>

<return xsi type="SOAP-ENC:ARRAY"

SOAP-ENC:ArrayType="xsd:string[2]">

<pfn> host3.ral.ac.uk/path4/file2 </pfn>




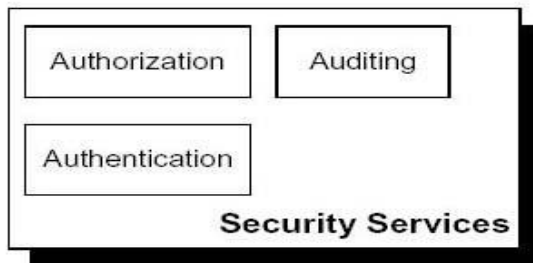

<pfn> host3.ral.ac.uk/path7/file4 </pfn>

</return>

</m:getAccessCostResponse>

</SOAP-ENV:Body>

</SOAP-ENV: Envelope



Основные группы сервисов



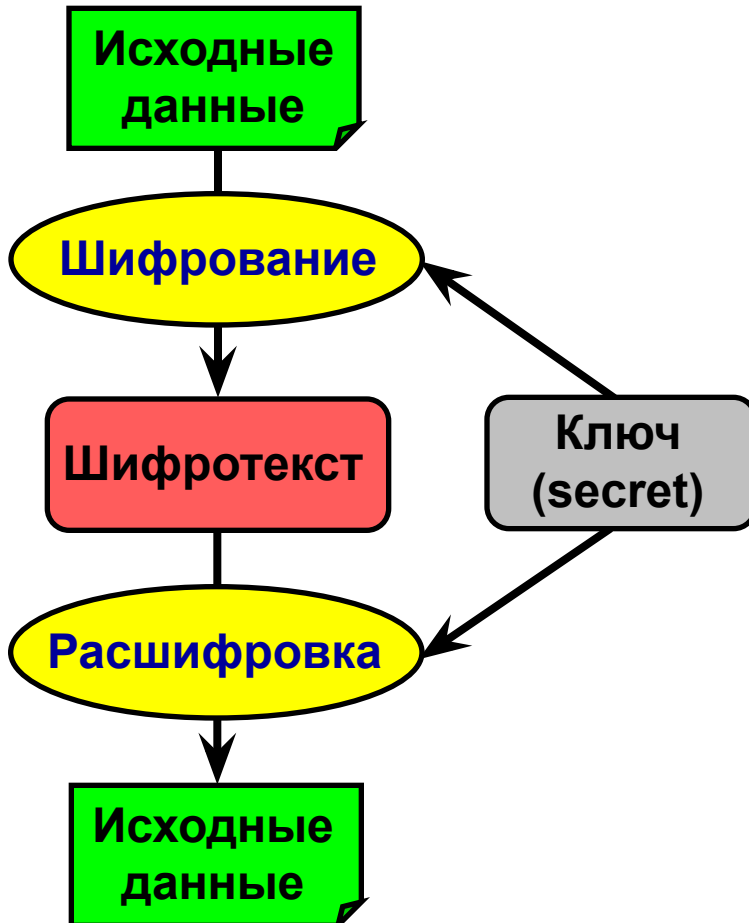
## Три основных аспекта безопасности:

**Privacy** – Обмен сообщениями должен быть приватным.  
(доступность передаваемых данных только участникам диалога)

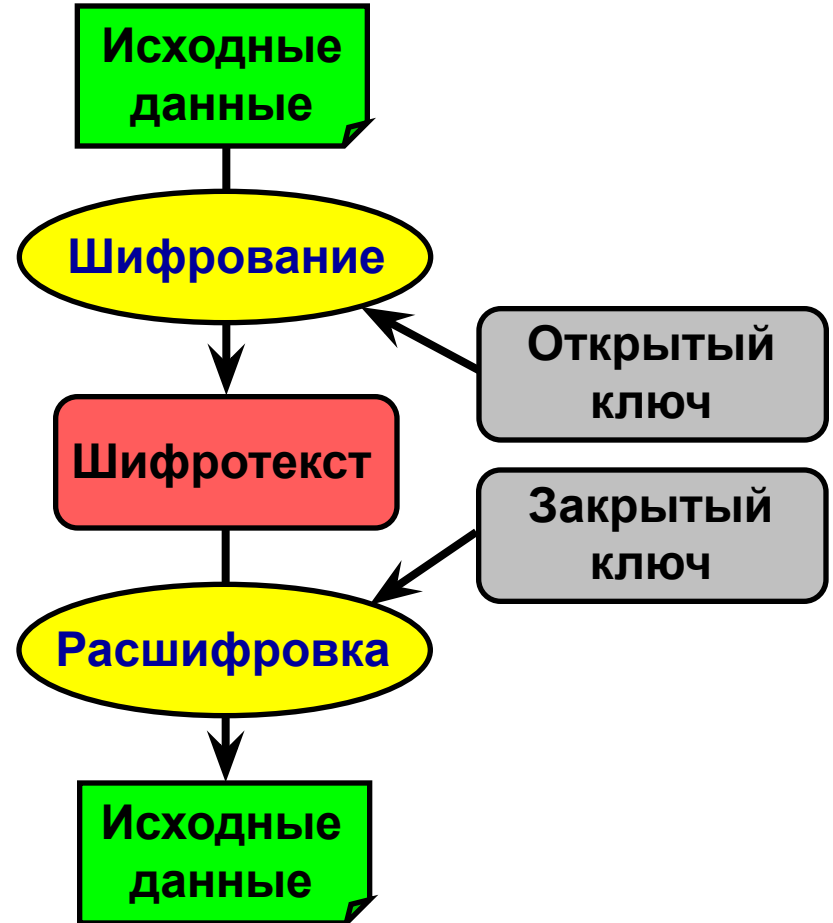
**Integrity** – Целостность данных, т.е. неизменность передаваемых данных

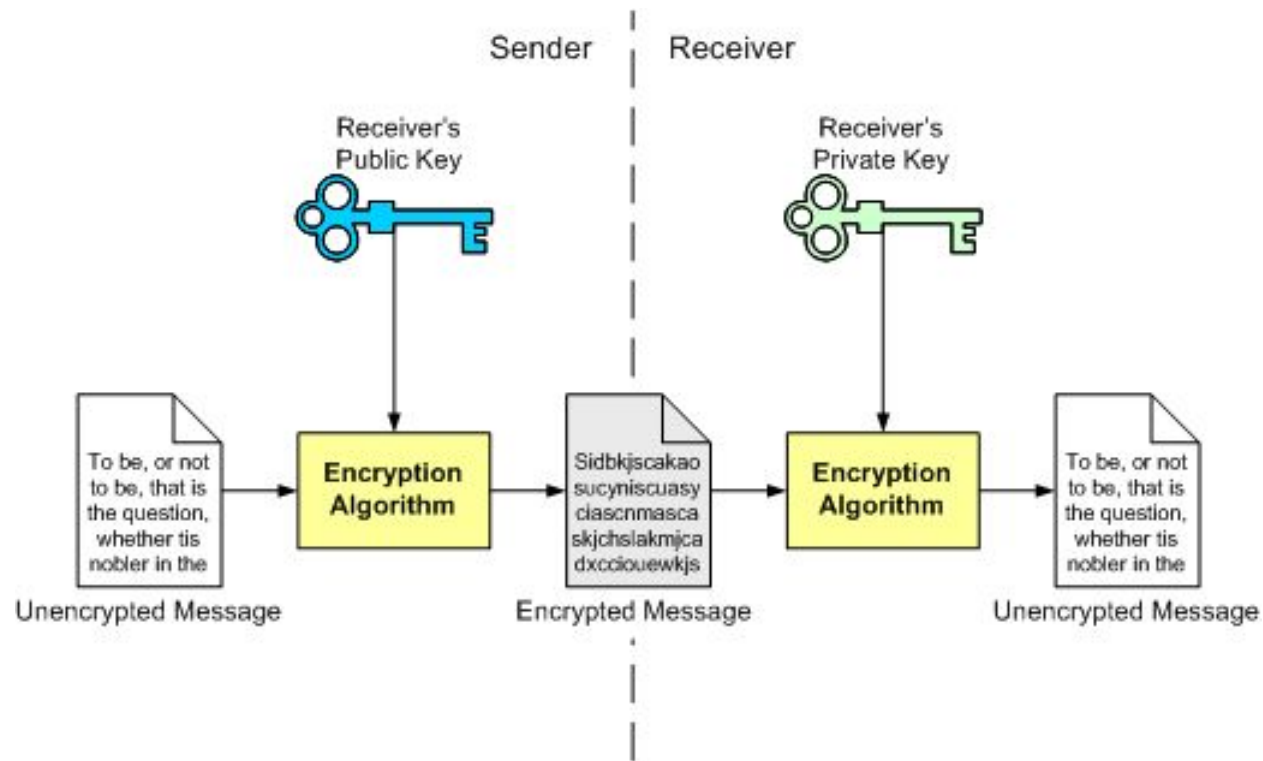
**Authentication** – Идентификация сторон, участвующих в диалоге  
(проверка подлинности сущности)

## Симметричный алгоритм

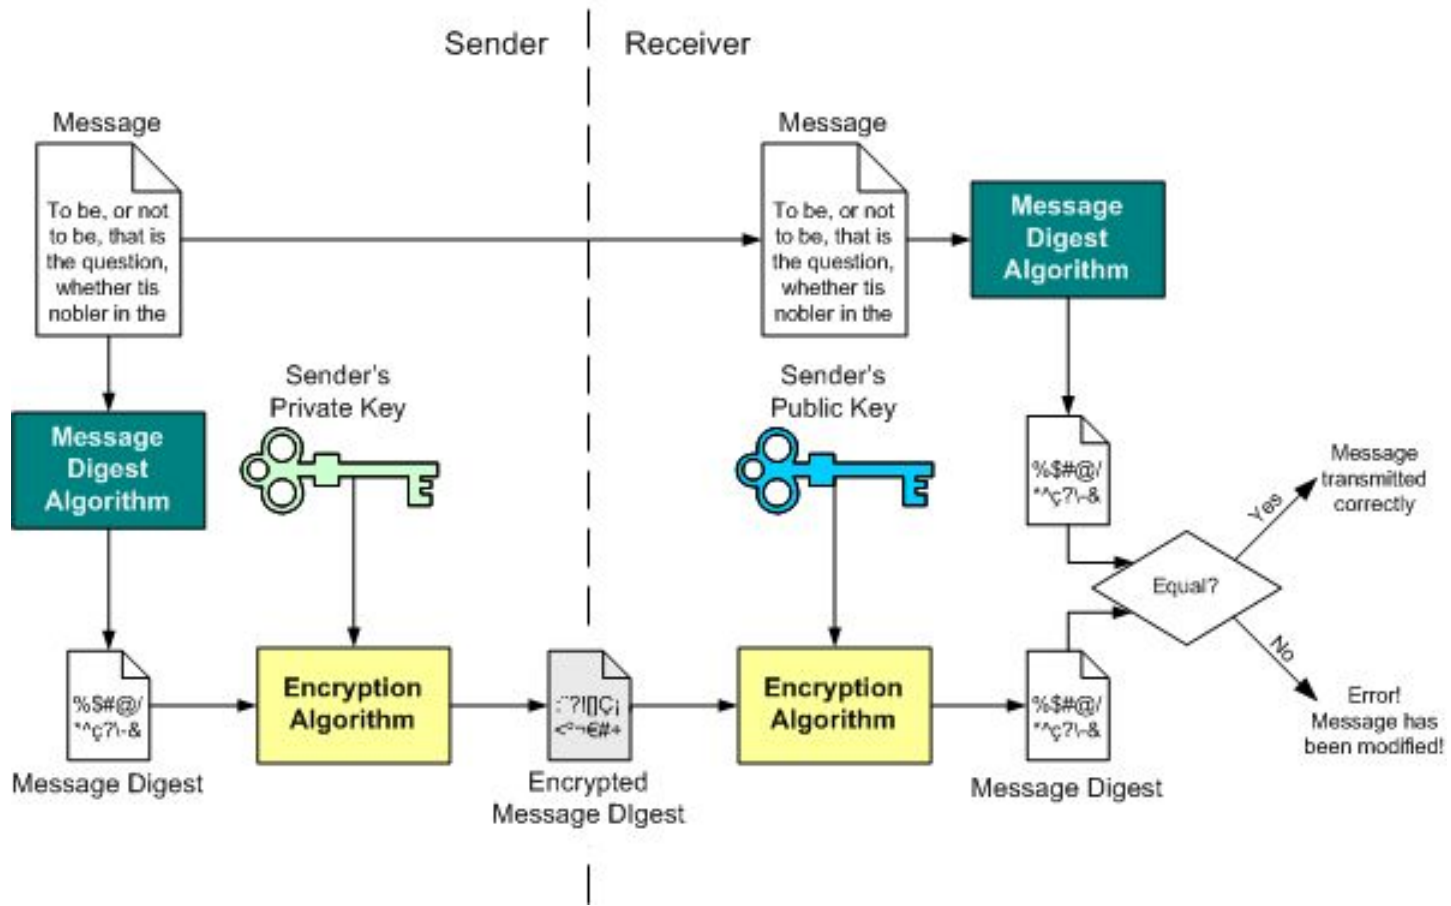


## Несимметричный алгоритм



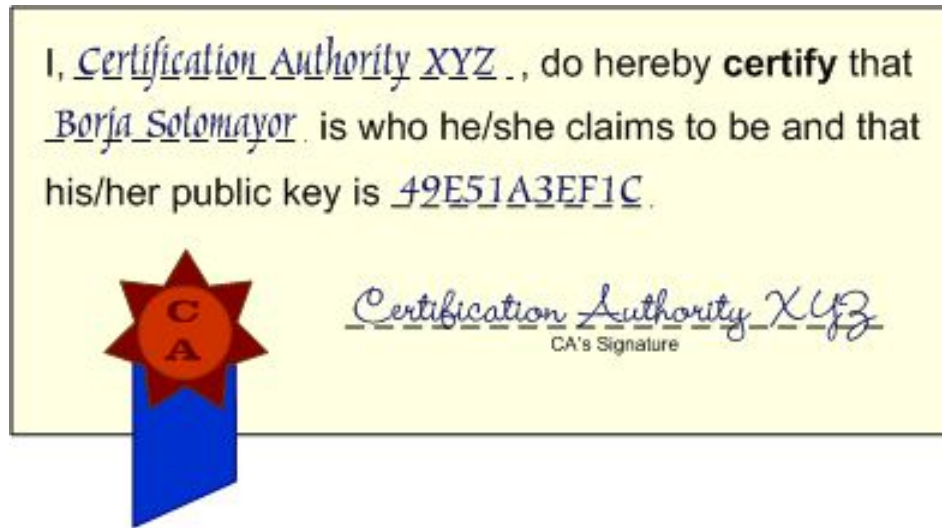


## Digital signatures (Цифровая подпись)



## Certificates and certificate authorities

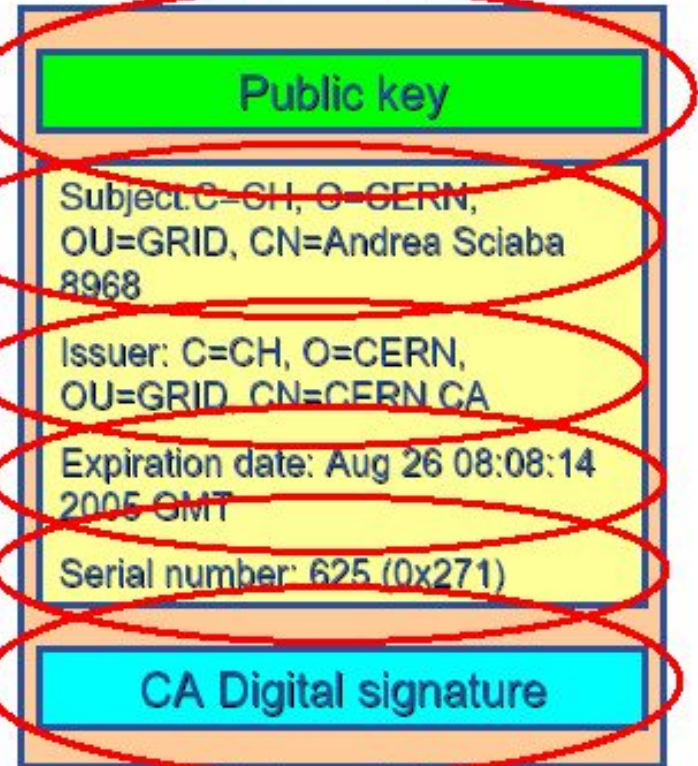
*digital certificate – цифровой документ, подтверждающий, что данный public key принадлежит конкретному пользователю (системе, сервису). Этот документ подписан 3-й стороной, называемой certificate authority (CA). Доверие сертификату строится на доверии третьей стороне, подписавшей этот сертификат*



- An X.509 Certificate contains:

- owner's public key;
- identity of the owner;
- info on the CA;
- time of validity;
- Serial number;
- digital signature of the CA

Structure of a X.509 certificate




- **Алиса (А)** хочет аутентифицировать **Боба (Б)**.
- **Б** посылает свой сертификат Алисе, она проверяет правильность сертификата и подпись (имеет РК СА).
- **А** посылает Бобу произвольную фразу (challenge) с просьбой зашифровать её закрытым ключом Боба.
- **Б** шифрует пришедшие данные и отправляет ответ (response) Алисе.
- **А** расшифровывает ответ Боба с помощью переданного ранее открытого ключа и сравнивает результат с эталонной фразой.
- Если сравнение успешно, то Боб действительно владеет закрытым ключом, соответствующим сертификату.

## Проблемы:

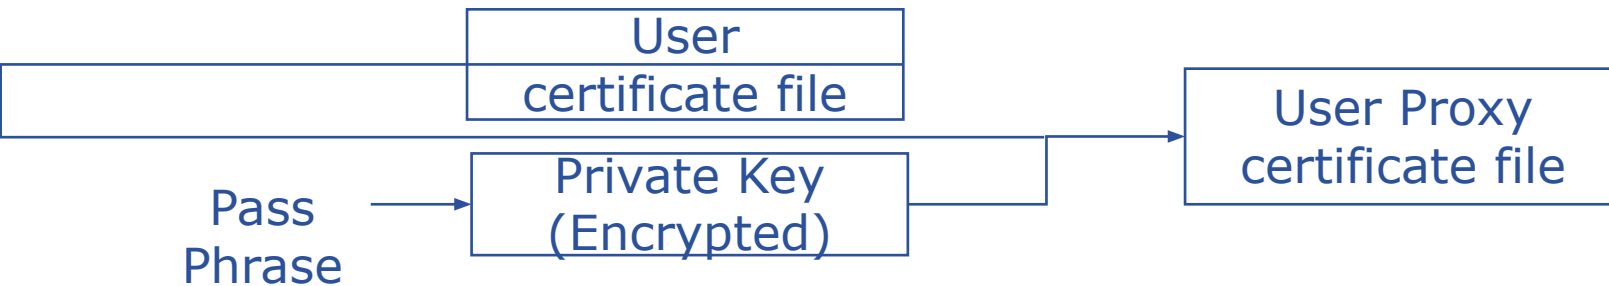
Single sign-on

Delegation

однократное предъявление  
первичного закрытого ключа



## Proxy-certificate




Применение проxy-сертификата для аутентификации избавляет пользователя от необходимости вводить свой пароль при каждом взаимодействии с сервисами.

Можно передавать свои проxy-сертификаты другим субъектам для выполнения операций от своего имени.

**Ограниченное время действия**



- voms-proxy-init –voms picard
- voms-proxy-info --all
- subject : /C=RU/O=RDIG/OU=users/OU=pnpi.nw.ru/CN=Nikolai Klopov/CN=proxy
- issuer : /C=RU/O=RDIG/OU=users/OU=pnpi.nw.ru/CN=Nikolai Klopov
- identity : /C=RU/O=RDIG/OU=users/OU=pnpi.nw.ru/CN=Nikolai Klopov
- type : proxy
- strength : 512 bits
- path : /tmp/x509up\_u6901
- timeleft : 11:59:43
- === VO picard extension information ===
- VO : picard
- subject : /C=RU/O=RDIG/OU=users/OU=pnpi.nw.ru/CN=Nikolai Klopov
- issuer : /C=IT/O=INFN/OU=Host/L=CNAF/CN=cert-voms-01.cnaf.infn.it
- attribute : /picard/Role=NULL/Capability=NULL



Каждый Grid ресурс должен определить действия, которые может выполнять пользователь.

- Database server: read/write/create permission?
- Compute element: permission to execute?
- Storage Element: write/read access?

- Обычно выполняется через **grid-mapfiles**:

...

```
"/C=CH/O=CERN/OU=GRID/CN=Simone Campana 7461" .dteam
```

```
"/C=CH/O=CERN/OU=GRID/CN=Andrea Sciaba 8968" .cms
```

```
"/C=CH/O=CERN/OU=GRID/CN=Patricia Mendez Lorenzo-ALICE" .alice
```

...

- Много пользователей и привелегий -> трудно администрировать!

Пользователи объединяются в Виртуальные Организации (VO).

- «Динамическое собрание одиночек и организаций, гибко, безопасно и координировано разделяющее ресурсы» -- LCG-2 User Guide.
- **VO с технической точки зрения:** LDAP или HTTP или VOMS ресурс, перечисляющий Distinguished Names сертификатов пользователей конкретной VO.
- **LCG-2:** файл /etc/grid-security/grid-mapfile, один сертификат – одна виртуальная организация, нет разделения пользовательских ролей внутри VO.
- **VOMS:** призвана для управления ролью пользователя внутри VO и создания пользовательских групп. Вместо использования LDAP/HTTP для отображения пользователей будет использоваться VOMS-запросы. Внутренняя структура хранилища – Relational Database.

- **VOMS** presents a user's VO membership information as an extension to their X509 proxy certificate.
- GROUP: {string that names the group}
- ROLE: {string that gives the user role(s) in this group}
- CAP: {special capabilities assigned to this role}
- **Example: A user works on ATLAS high energy physics experiment**

GROUP	ROLE	Special CAPability
ATLAS	user	none
ATLAS CAL	user	none
ATLAS LARG	update	10G disk space
ATLAS FCAL	administrator	full write privileges

- **Гетерогенность**

- Данные хранятся на различных устройствах (диски, ленты), использующих различные методы доступа

- **Распределенность**

- Данные хранятся на различных сайтах, где отсутствует общая разделяемая файловая система
- Данные могут перемещаться между различными сайтами

- **Различные административные домены**

- Данные хранятся там, куда обычный доступ вам запрещен

- Необходим общий интерфейс к устройствам

- Storage Resource Manager (SRM)

- Необходим способ определения местоположения файлов

- File and Replica Catalogs

- Необходима управляемая, надежная передача файлов

- File transfer and placement services

- Необходима общая модель безопасности

- ACLs enforcement based on Grid identities – DNs

- **Storage Element – common interface to storage**

- Storage Resource Manager
- POSIX-I/O
- Access protocols

Castor, dCache, DPM, ...  
 gLite-I/O, rfiio, dcap, xrootd  
 gsiftp, https, rfiio, ...

- **Catalogs – keep track where data is stored**

- File Catalog

### Catalog

- Replica Catalog
- File Authorization Service
- Metadata Catalog

gLite File and Replica

### catalogs

- **File Transfer – scheduled reliable file transfer**

- Data Scheduler
- File Transfer Service
- File Placement Service

Application specific

glite-url-copy;

gLite FTS and

(FTS and catalog interaction)

gLite FPS

- Данные хранятся на **disk pool servers** или **Mass Storage Systems**
- Управление этими ресурсами должно обеспечивать:
  - Прозрачный доступ к файлам (migration to/from disk pool)
  - Выделение места для файлов (Space reservation)
  - Управление временем жизни файлов (Life time management)
  - ....
- **SRM (Storage Resource Manager)** сервис реализует все эти требования:
  - SRM is a Grid Service that takes care of local storage interaction and provides a Grid interface to outside world
- Interactions with the SRM is typically hidden by higher level services



- Имена файлов на SE имеют только локальное значение:

- /tmp/picard/file1 (Unix)

- srm://castorgrid.cern.ch:8443/srm/managerv1?SFN=/castor/cern.ch/file1

(SRM Site URL – SURL)

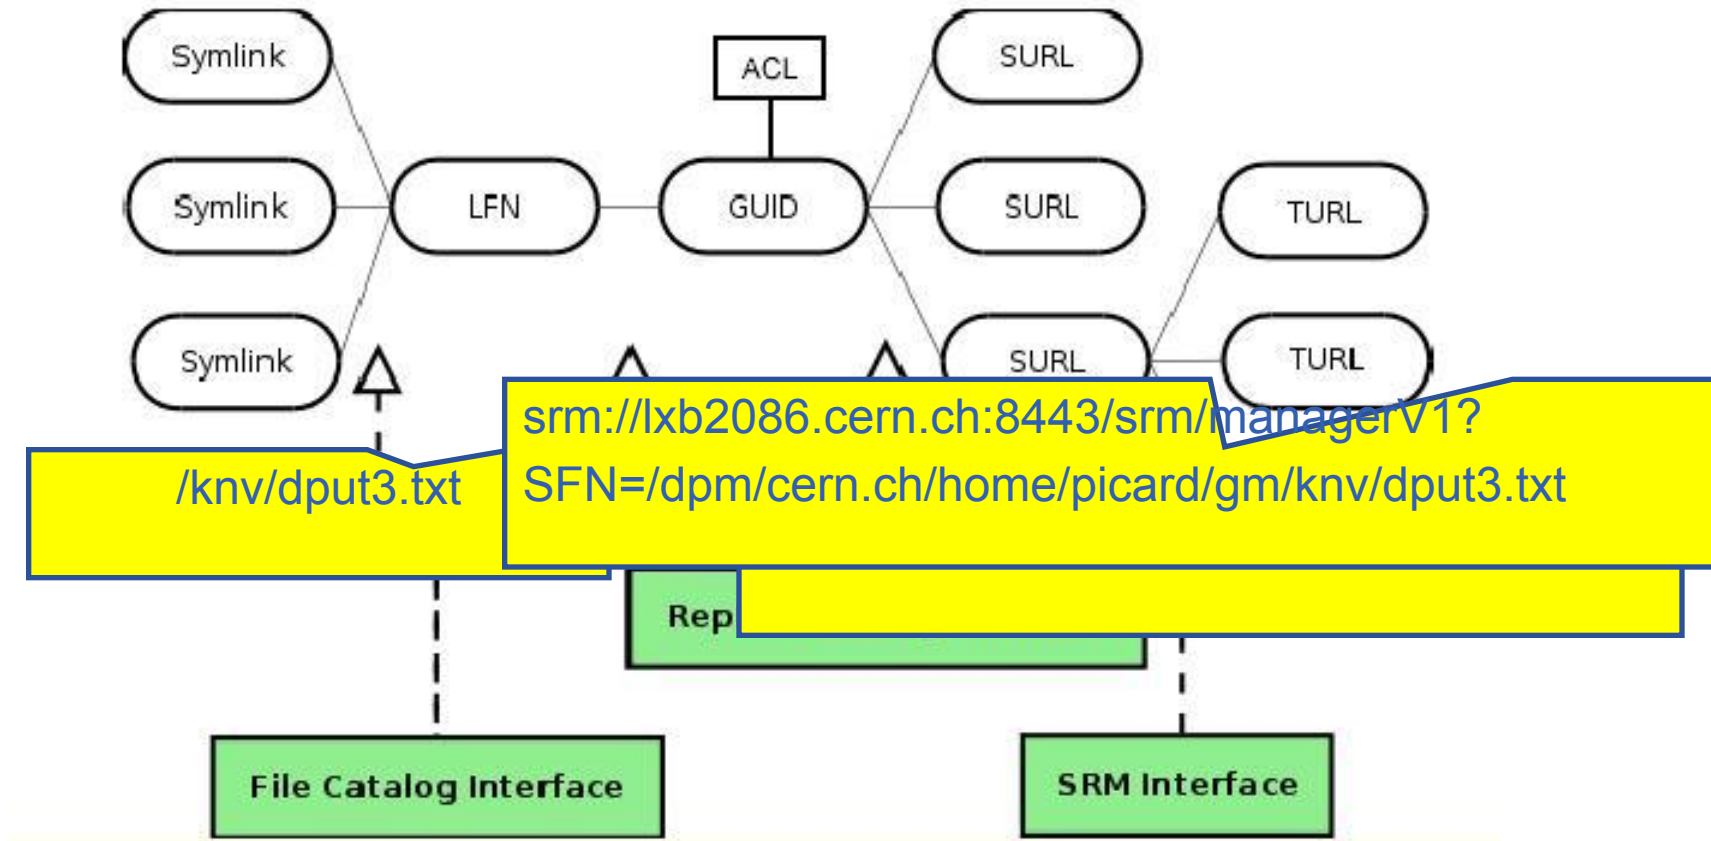
Локальная система может преобразовывать имена файлов, напр. SURL не может использоваться прямо, он должен быть преобразован SRM в **Transfer URL (TURL)** :

gsiftp://se05.cern.ch/scratch/file05

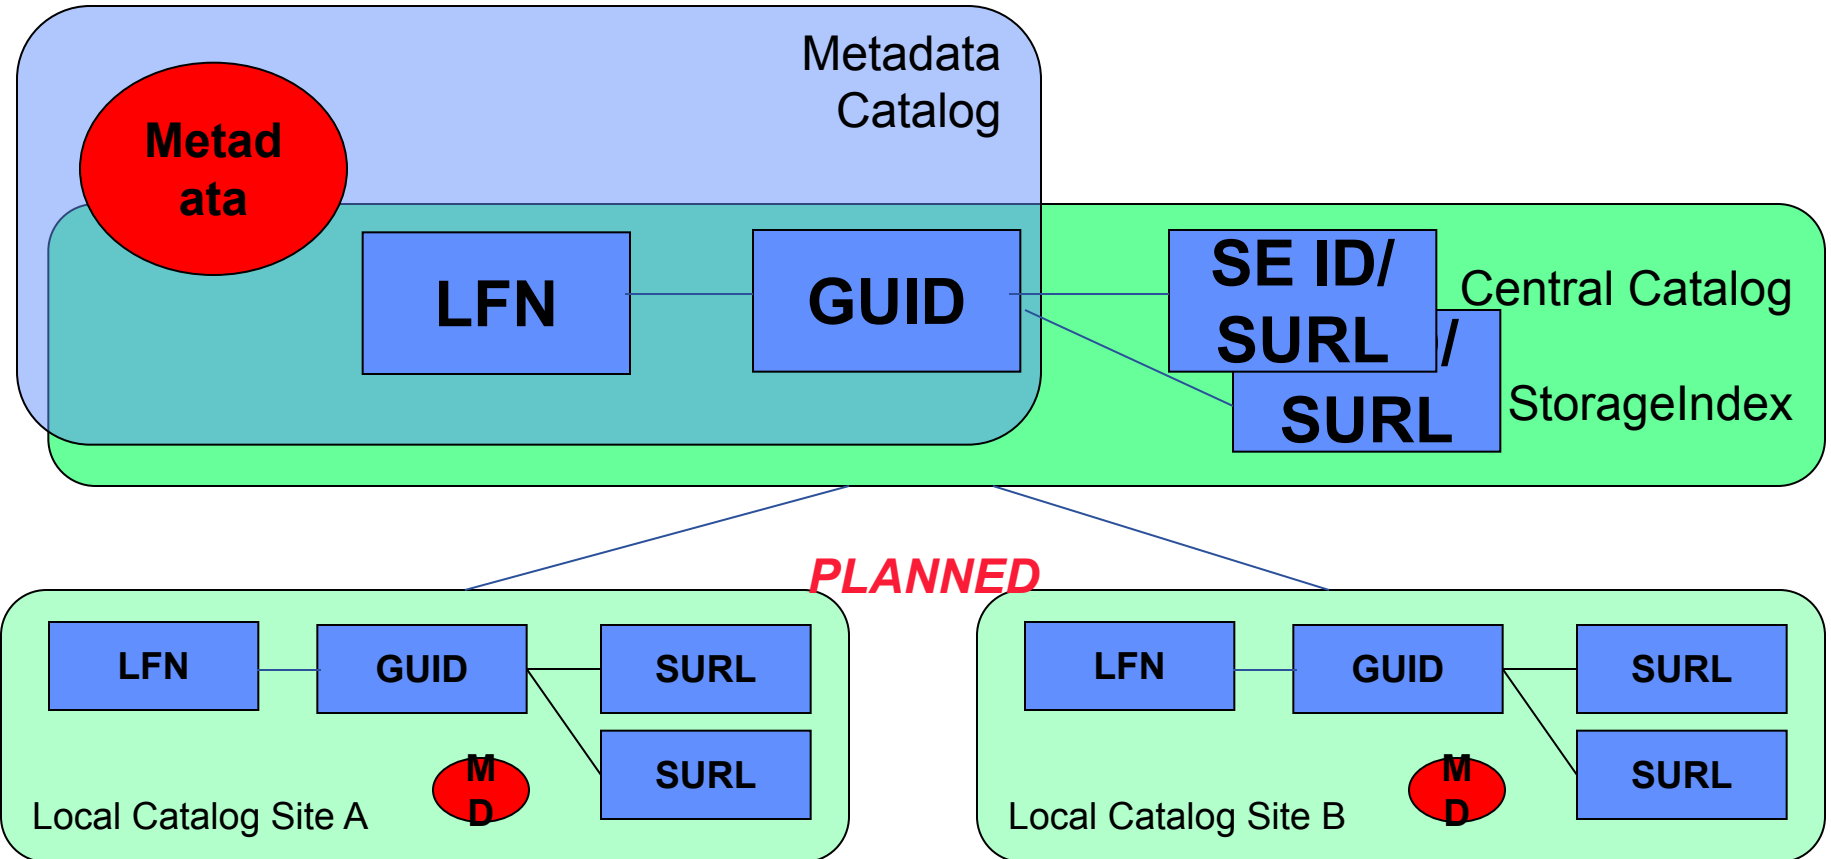


Для доступа к файлам необходим подход, позволяющий абстрагироваться от локальной системы имен и обеспечить общий для GRID среды механизм имен файлов


# Data Naming



- Позволяет определить, где размещены файлы в Grid
- Может определить дополнительную семантику на LFN (атрибуты, ACLs,..)
- Позволяет определить местоположение реплик



- Позволяет определить, где размещены файлы в Grid
- Может определить дополнительную семантику на LFN (атрибуты, ACLs,..)
- Позволяет определить местоположение реплик

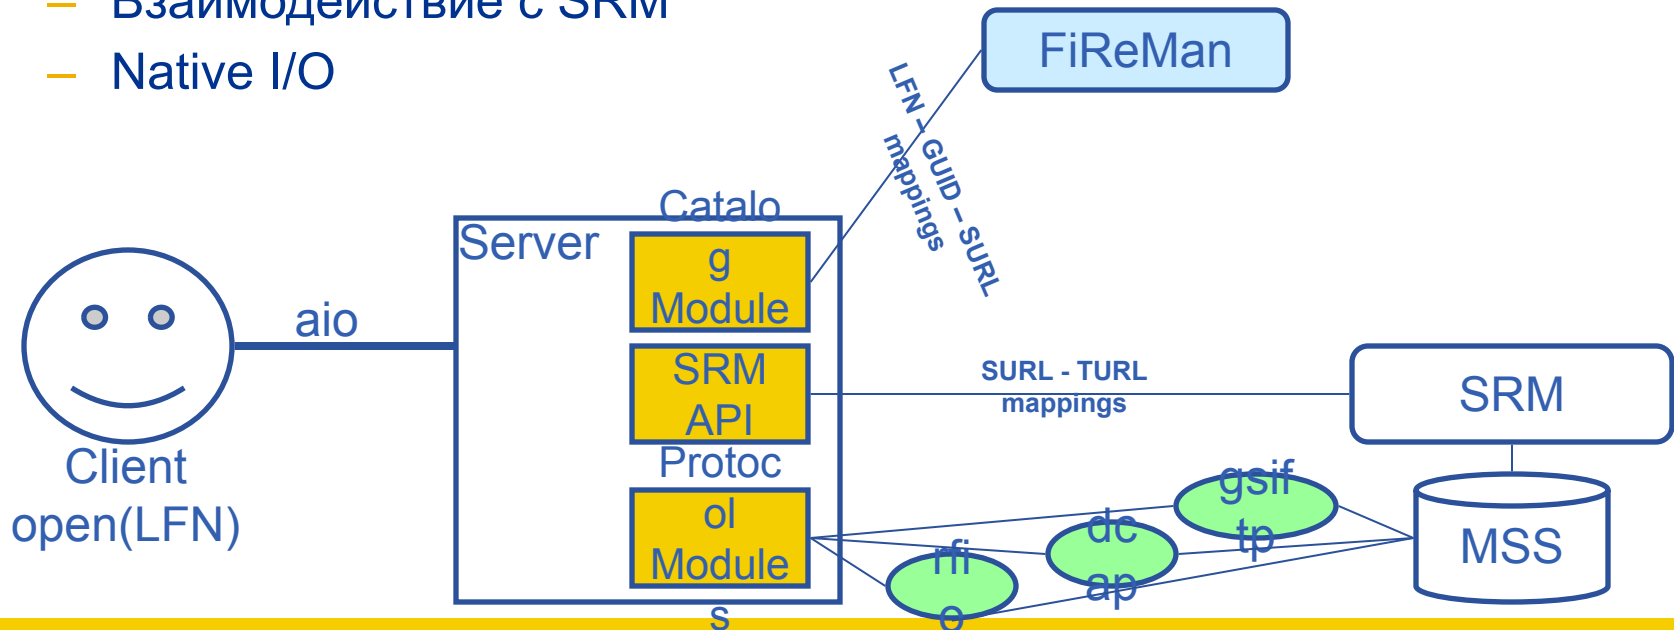



- glite-catalog-ls
- glite-catalog-stat
- glite-catalog-mkdir
- glite-catalog-rmdir
- glite-catalog-mv
- glite-catalog-symlink
- glite-catalog-create
- glite-catalog-rm
- **glite-catalog-setreplica**
- **glite-catalog-getreplica**
- p - allow to change the permissions
- d - delete the entry
- r - read the file
- w - write to the file
- l - list contents
- x - execute
- g - get the meta data of the file
- s - set the meta data of the file
- **glite-catalog-getattr**
- **glite-catalog-setattr**
- **glite-catalog-chmod**
- **glite-catalog-getacl**
- **glite-catalog-setacl**

- glite-get
- glite-put
- glite-rm


```
# LFN: /knv/dput4.txt
# User: /C=RU/O=RDIG/OU=users/OU=pnpi.nw.ru/CN=Nikolai Klopov
# Group: egee-group
# Base perms: user pdrwl-gs, group --r-l-g-, other -----
```

- Клиент использует **API library** или **Command Line Interface**
  - GUID или LFN может использоваться, напр. `open("/grid/myFile")`
- **GSI Delegation to gLite I/O Server**
- **Сервер выполняет все операции от имени клиента**
  - Преобразование LFN/GUID в SURL и TURL
- **Встроенные операции:**
  - Взаимодействие с каталогом
  - Взаимодействие с SRM
  - Native I/O





- **File Transfer/Placement Service (FTS,FPS)**
  - База данных заданий на передачу файлов
  - Предоставляет Transfer Web Service интерфейс для клиента (submit, cancel, status)
  - Имеет Web Interface
  - Модифицирует Catalog если необходимо
- **Transfer Agent**
  - Основные действия
    - Получает задания из Transfer Job Database
    - Управляет передачей через множество каналов
    - Мониторит статус и модифицирует Transfer Job Database
- **Transfer Service (glite-url-copy)**
  - Фактически выполняет передачу: SRM – SRM, gsiftp – SRM, gsiftp – gsiftp
  - Мониторирование



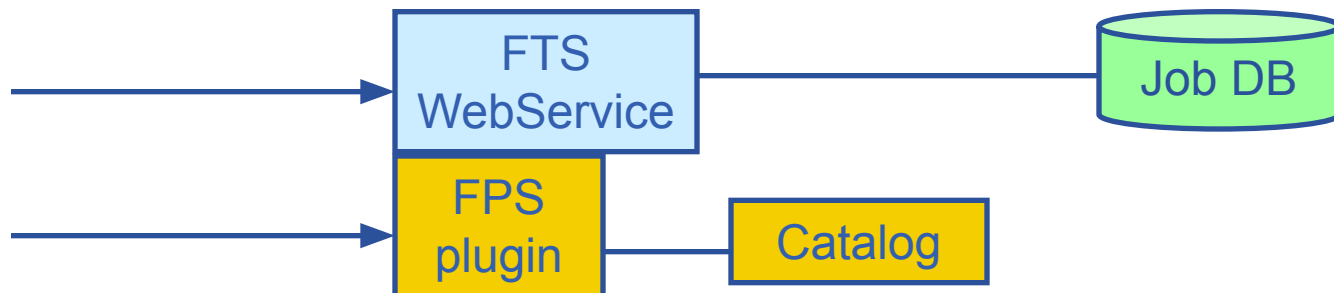


- **File Transfer Service (FTS)**

- Действует только через SRM SURLs or gsiftp URLs
- `submit(source-SURL, destination-SURL)`

- **File Placement Service (FPS)**

- Позволяет работать с LFNs
- Взаимодействует с replica catalogs
- Регистрирует реплики в каталоге реплик
- `submit(transferJobs)` (`transferJob = sourceLFN, destinationSE`)



В распределенной среде важна возможность получать информацию о доступных в данный момент ресурсах. Эта информация может включать:

- сайты (CE), способные выполнить данное задание, их загрузка, ПО, установленное на них.
- сайты, предоставляющие возможности для хранения данных, включая их статус, максимальный размер и число файлов, которые могут быть сохранены.
- данные мониторингования процесса выполнения задания

*If you are a user*

Retrieve information of Grid resources and status

Get the information of your jobs status

*If you are a middleware developer*

Workload Management System:  
Matching job requirements and Grid resources

Monitoring Services:  
Retrieving information of Grid Resources status and availability

*If you are site manager or service*

You “generate” the information for example relative to your site or to a given service

- LCG-2 currently uses GT Monitoring and Discovery Service (MDS) architecture together with Berkley Database Information Indexes (BDII)
- The information system is built on *LDAP*  
*Light-weight Directory Access Protocol*
- A Schema describes the attributes and the types of the attributes associated with data objects
- Example:  
GlueSiteInfo


```
dataGridVersion: LCG-2_0_0
installationDate: 200404131100Z
objectClass: SiteInfo
siteName: nikhef.nl
siteSecurityContact: grid-support-admin@nikhef.nl
sysAdminContact: grid-support-admin@nikhef.nl
userSupportContact: grid-support-admin@nikhef.nl
```

## Основные шаги:

1. На каждом сайте **PROVIDERS** передают статическую и динамическую информацию о своем состоянии на **SERVERS**
2. **CENTRAL SYSTEM** опрашивает эти сервера и сохраняет полученные данные
3. Эта информация доступна через заданный **ACCESS** **PROTOCOL**
4. Центральная система предоставляет информацию в соответствии со **SCHEMA**, которая определяет стандарт на описание сетевых ресурсов

*BDII* является текущей *EGEE/LCG* Информационной Системой и основывается на *LDAP*


(a)



Иерархическая – структура типа дерева; потомок имеет только одного родителя. легко разделяется (partitions); легко отображается на физические устройства.

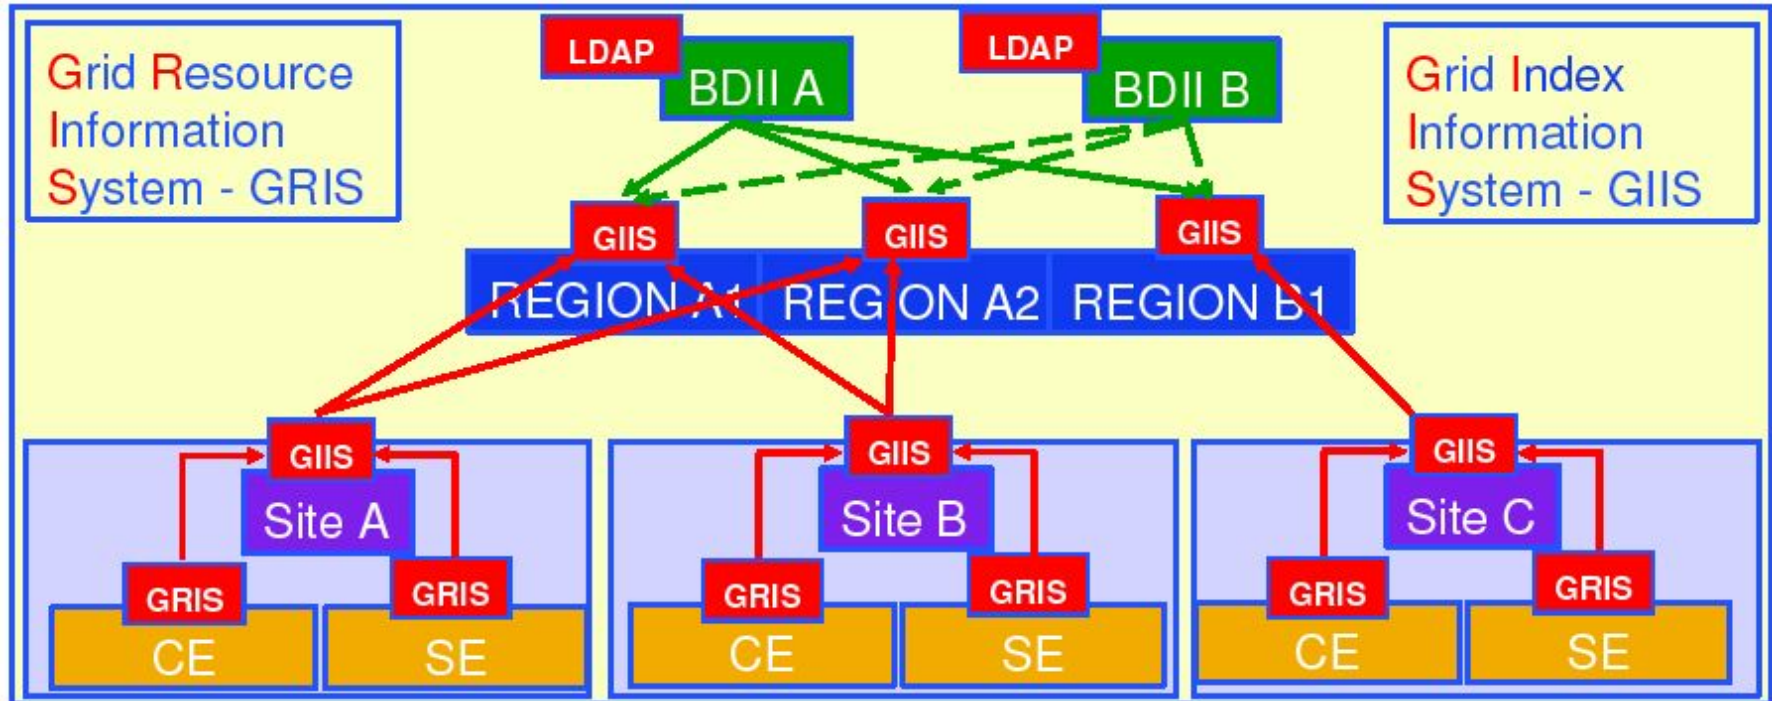
**BDII, LDAP**

(b)



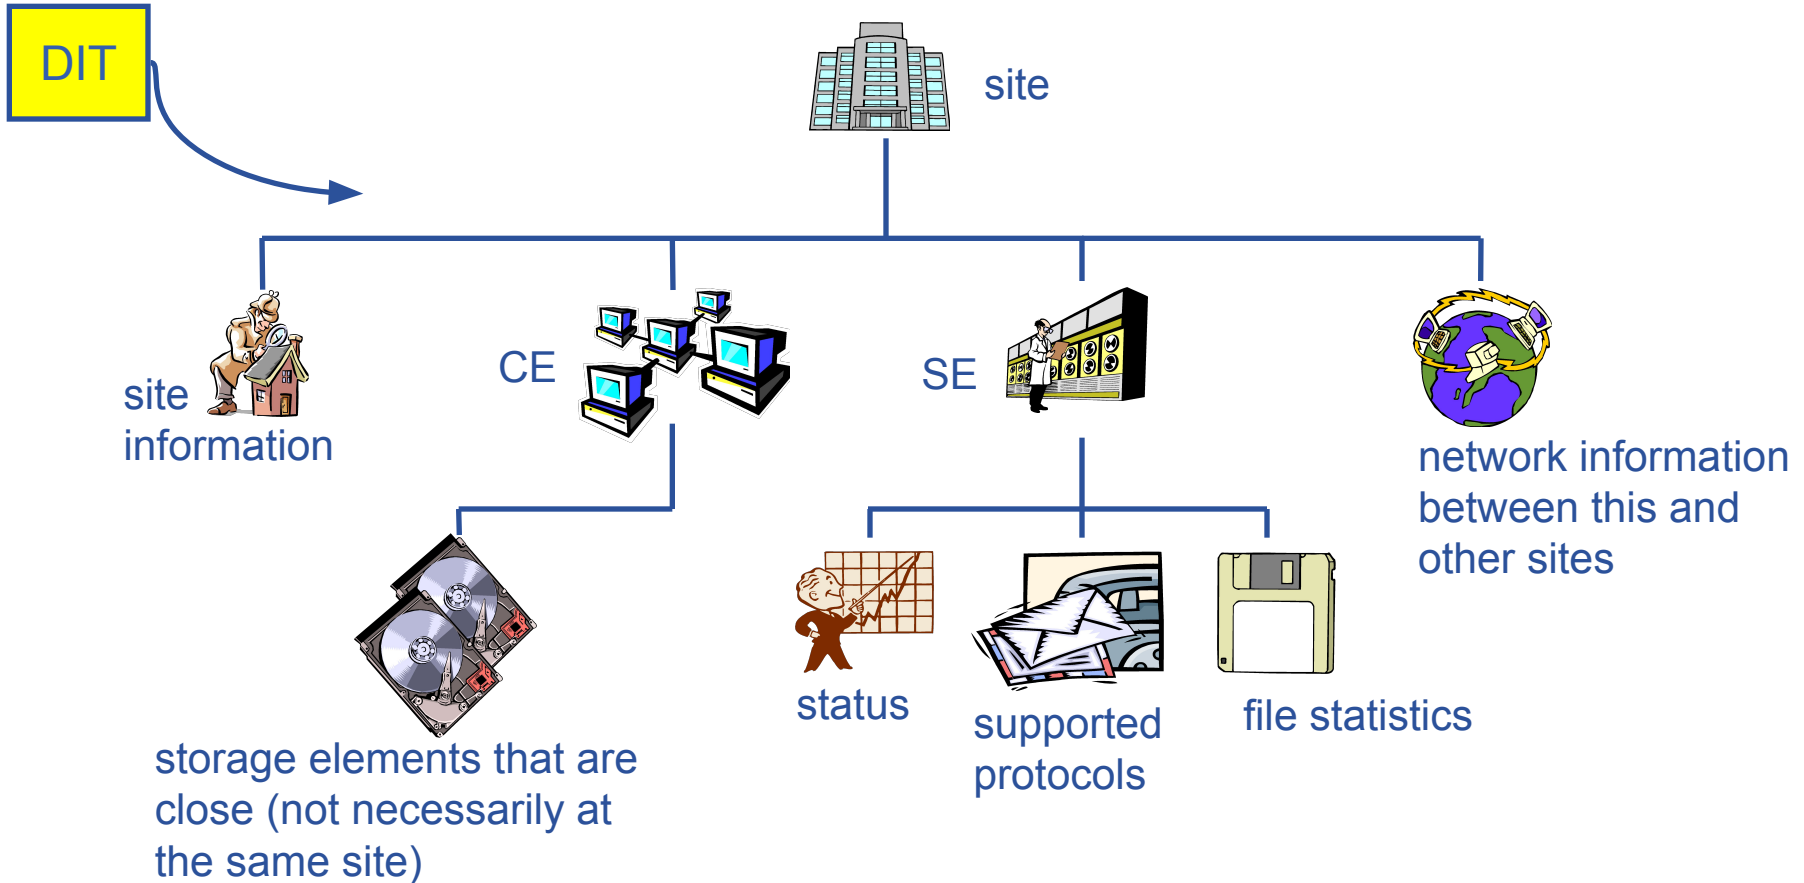
Реляционная – набор таблиц; Язык запросов (SQL) эффективный, широко распространенный

**R-GMA**



-- Иерархическая модель предоставления данных в информационной системе: **CE, SE** → **GRIS** → **GIIS** → **BDII** (GIIS в настоящее время заменяется на **BDII**)

-- Ресурсы описываются при помощи GLUE Schema.





## ATTRIBUTES FOR THE CE

- **Base Class for the CE information** (objectclass: GlueCETop) : No attributes
- **CE** (objectclass: GlueCE)
  - GlueCEUniqueID: **unique identifier for the CE**
  - GlueCEName: **human-readable name of the service**
- **CE Status** (objectclass: GlueCEState)
  - GlueCEStateRunningJobs: **number of running jobs**
  - GlueCEStateWaitingJobs: **number of jobs not running**
  - GlueCEStateTotalJobs: **total number of jobs (running + waiting)**
  - GlueCEStateStatus: **queue status: queueing (jobs accepted but not running), production (jobs accepted and run), closed (neither accepted nor run), draining (jobs not accepted but those already queued are running)**
  - GlueCEStateWorstResponseTime: **worst possible time between the submission of the job and the start of its execution**

### 3. ATTRIBUTES FOR THE SE

- ▣ Base Class (objectclass: GlueSETop): No attributes
- ▣ Architecture (objectclass: GlueSLArchitecture)
  - GlueSLArchitectureType: type of storage hardware (disk, tape, etc)
- ▣ Storage Service Access Protocol (objectclass: GlueSEAccessProtocol)
  - GlueSEAccessProtocolType: protocol type to access or transfer files
  - GlueSEAccessProtocolPort: port number for the protocol
  - GlueSEAccessProtocolVersion: protocol version
  - GlueSEAccessProtocolAccessTime: time to access a file using this protocol

### 4. MIXED ATTRIBUTES

- ▣ Association between one CE and one or more SEs (objectclass: GlueCESEBindGroup)
  - GlueCESEBindGroupCEUniqueID: unique ID for the CE
  - GlueCESEBindGroupSEUniqueID: unique ID for the SE

- LDAP не поддерживает агрегатные запросы на различные объекты, т.е. запрос основывается на атрибутах объекта.

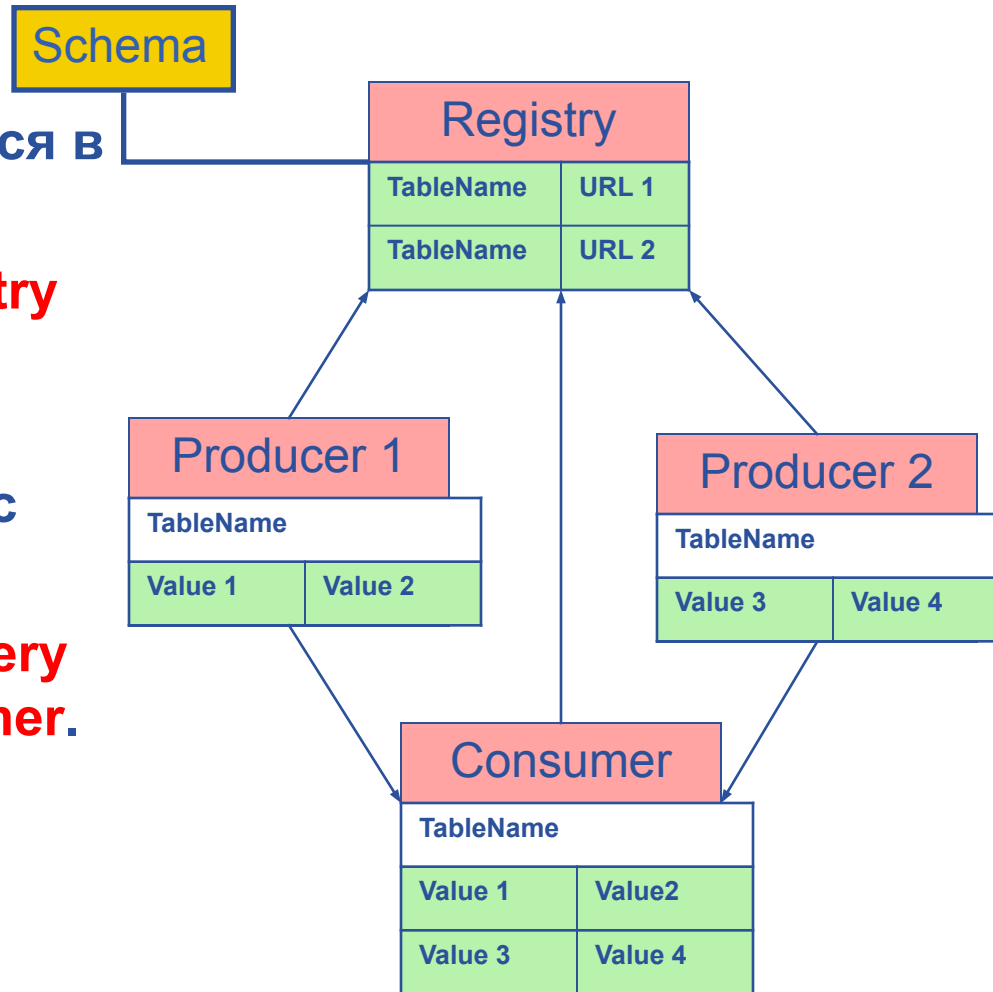
## R-GMA: Relation Grid Monitoring Architecture

- **Использует реляционную модель данных.**
  - Данные представляются в виде таблиц.
  - Структура данных определяется по колонкам.
  - Каждая запись есть строка (tuple).
  - Язык запросов - Structured Query Language (SQL).
- **Поддерживает различные типы запросов:**
  - streams
  - archives
  - lates-value


- Все **Producers** регистрируются в **Registry**, определяя **Schema**
- **Consumer** получает из **Registry** те URLs, которые могут выполнить его запрос.
- **Consumer** взаимодействует с этими **Producers**.
- **Producers** обрабатывают **query** и возвращают tuples **Consumer**.



**Виртуальная база данных**




- Queries posed against a virtual data base
- The Mediator must:
  - find the right Producers
  - combine information from them
- Hidden component – but vital to R-GMA
- Will eventually support full distributed queries but for now will only merge information from multiple producers for queries on one table or over multiple tables from one producer



Service				
URI	VO	type	emailContact	site
gppse01	alice	SE	sysad@rl.ac.uk	RAL
gppse01	atlas	SE	sysad@rl.ac.uk	RAL
gppse02	cms	SE	sysad@rl.ac.uk	RAL
lxshare0404	alice	SE	sysad@cern.ch	CERN
lxshare0404	atlas	SE	sysad@cern.ch	CERN

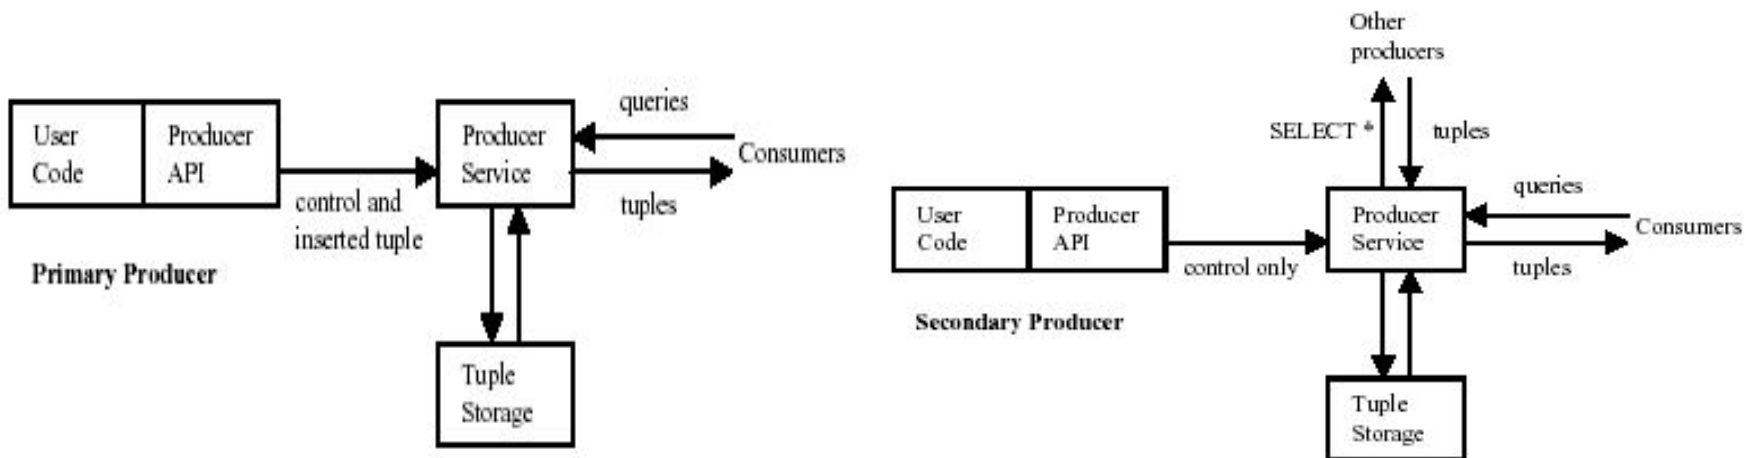
ServiceStatus				
URI	VO	type	up	status
gppse01	alice	SE	y	SE is running
gppse01	atlas	SE	y	SE is running
gppse02	cms	SE	n	SE ERROR 101
lxshare0404	alice	SE	y	SE is running
lxshare0404	atlas	SE	y	SE is running



Result Set (Consumer)	
URI	emailContact
gppse02	sysad@rl.ac.uk

```
SELECT Service.URI Service.emailContact FROM Service S, ServiceStatus SS
WHERE (S.URI= SS.URI and SS.up='n')
```

# R-GMA: Producers




## Primary Producer


user code периодически inserts tuples в storage, который поддерживается Primary Producer service. Producer service автономно отвечает на запросы consumer.

## On-demand Producer

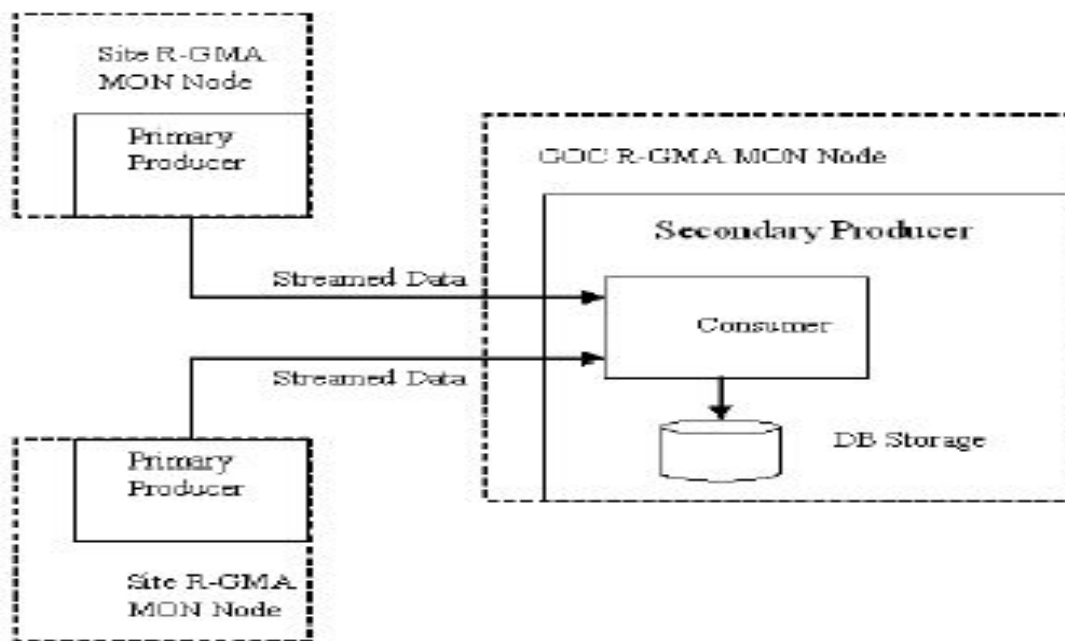
Нет внутреннего хранилища, данные выдаются User Code в ответ на запрос

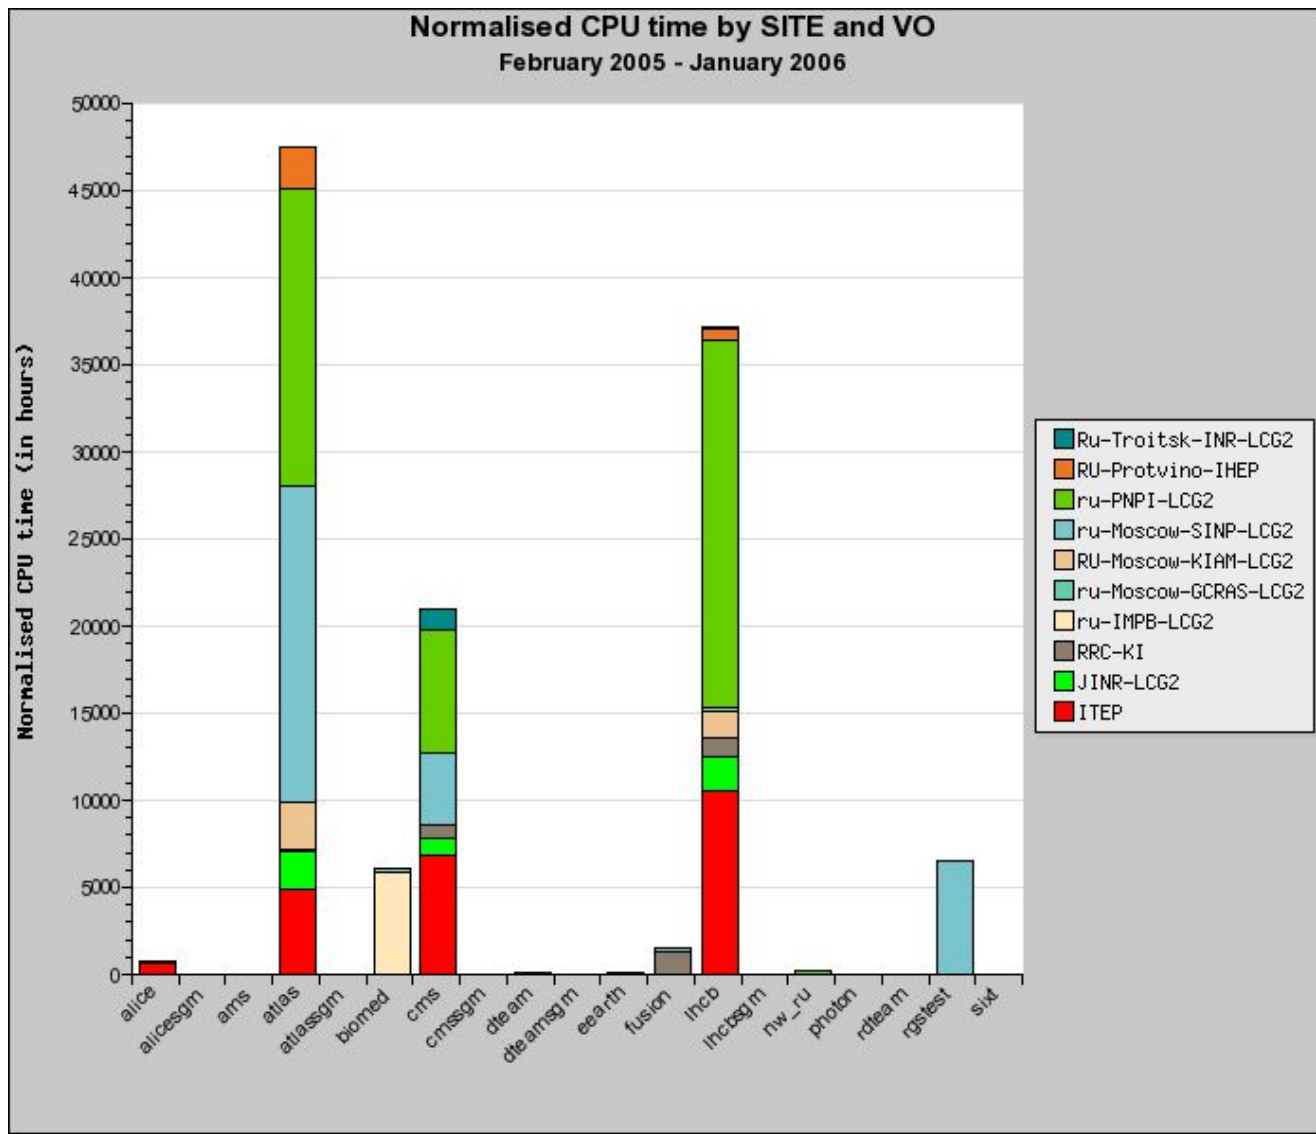






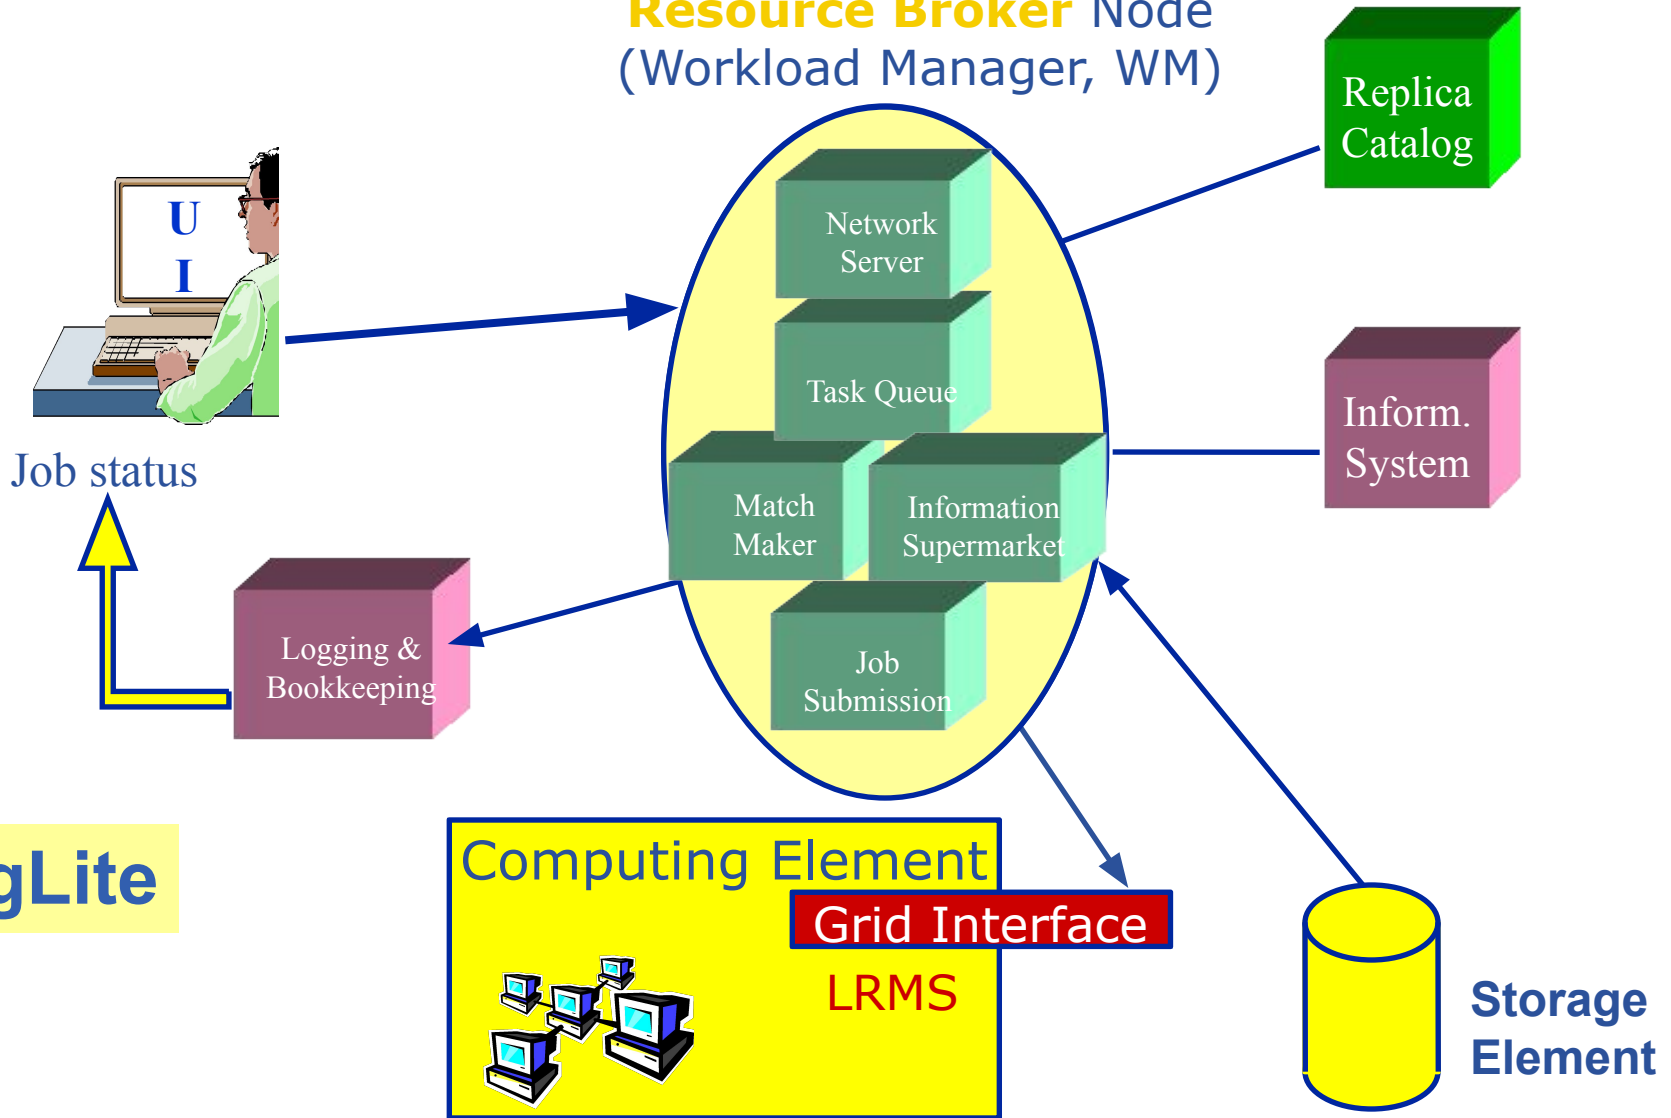
- Application runs on a site to process GateKeeper and PBS log files
  - Log files contain the User ID, Job Number and Resources used
  - Parsed log files are then published into a schema using R-GMA
- Log file data merged into one large accounting record
- R-GMA used to publish all accounting records per site
- Published records streamed to a Secondary Producer
  - Located on the GOC – aggregates records from all sites
  - Accounting records stored in a database






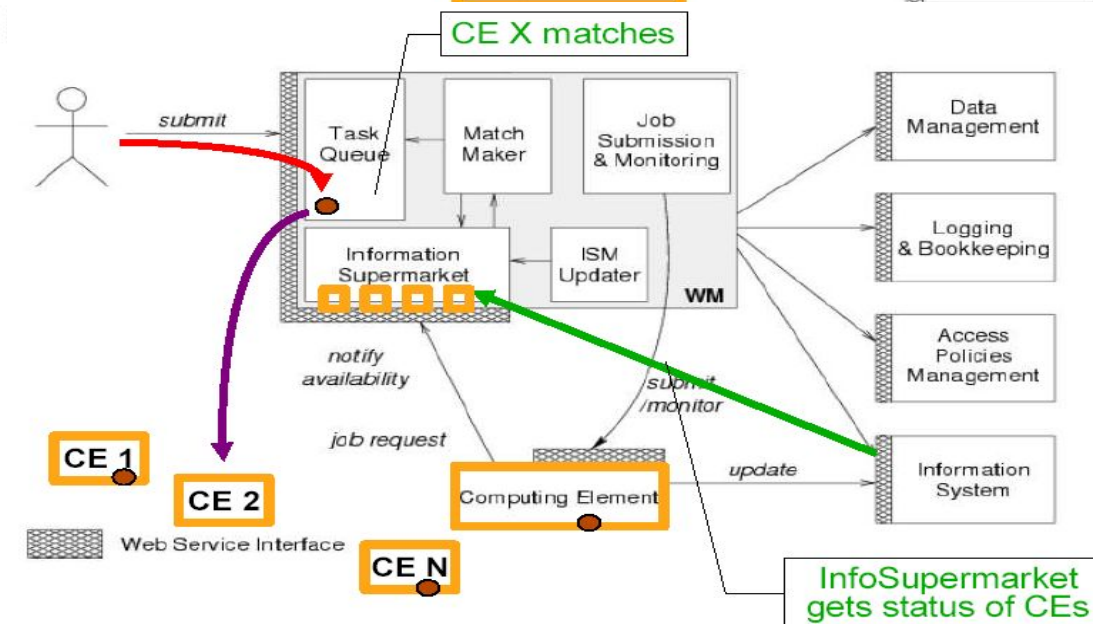
- Сервисы управления заданиями (Job Management Services )
  - **computing element**
    - *job management (запуск и управление заданиями)*
    - *Информирование о своих характеристиках и статусе*
  - **workload management**
    - *управление запуском заданий*
  - **accounting**
    - *computing, storage and network resources*
  - **job provenance**
    - *Сохранение данных о запущенных заданиях, условий выполнения и окружения и т.п. На длительный период времени*
      - *debugging, post-mortem analysis, comparison of job execution*
  - **package manager**
    - *automates the process of installing, upgrading, configuring, and removing software packages from a shared area on a grid site.*
      - *extension of a traditional package management system to a Grid*

## Resource Broker Node (Workload Manager, WM)





Lazy scheduling (pool mode)



Eager scheduling (push mode)

Web Service Interface

- ISM represents one of the most notable improvements in the WM as inherited from the EU DataGrid (EDG) project
  - **decoupling between the collection of information concerning resources and its use**
    - **allows flexible application of different policies**
- The ISM basically consists of a repository of resource information that is available in read only mode to the matchmaking engine
  - **the update is the result of**
    - **the arrival of notifications**
    - **active polling of resources**
    - **some arbitrary combination of both**
  - **can be configured so that certain notifications can trigger the matchmaking engine**
    - **improve the modularity of the software**
    - **support the implementation of lazy scheduling policies**

- The Task Queue
  - **Возможность сохранения запроса на запуск задания, если отсутствуют ресурсы, удовлетворяющие заданным требованиям (Non-matching requests)**
- Non-matching requests
  - **будут выбираться из очереди или периодически**
    - **eager scheduling**
  - **Или как только нотификация о доступности ресурса появится в ISM**
    - **lazy scheduling**



- L&B tracks jobs in terms of *events*
  - **important points of job life**
    - **submission, finding a matching CE, starting execution etc**
      - *gathered from various WMS components*
- The events are passed to a physically close component of the L&B infrastructure
  - **locallogger**
    - **avoid network problems**
      - *stores them in a local disk file and takes over the responsibility to deliver them further*
- The destination of an event is one of *bookkeeping servers*
  - **assigned statically to a job upon its submission**
    - **processes the incoming events to give a higher level view on the job states**
      - Submitted, Running, Done
    - **various recorded attributes**
      - *JDL, destination CE name, job exit code*
- Retrieval of both job states and raw events is available via legacy (EDG) and WS querying interfaces
  - **user may also register for receiving notifications on particular job state changes**

WMS components handling the job during its lifetime and performing the submission


- **Job Adapter**
  - **is responsible for**
    - making the final touches to the JDL expression for a job, before it is passed to CondorC for the actual submission
    - creating the job wrapper script that creates the appropriate execution environment in the CE worker node
      - *transfer of the input and of the output sandboxes*
- **CondorC**
  - **responsible for**
    - performing the actual job management operations
      - *job submission, job removal*
- **DAGMan**
  - **meta-scheduler**
    - purpose is to navigate the graph
    - determine which nodes are free of dependencies
    - follow the execution of the corresponding jobs.
- **Log Monitor**
  - **is responsible for**
    - watching the CondorC log file
    - intercepting interesting events concerning active jobs
      - *events affecting the job state machine*
    - triggering appropriate actions.

- Поддерживаемые атрибуты можно разделить на 2 категории:
  - Атрибуты задания (Job Attributes)
    - Определяют само задание
  - Ресурсы
    - Используются Workload Manager для matchmaking algorithm (выбрать “наилучший” ресурс для запуска задания)
    - **Computing Resource**
      - Используются для определения *Requirements* и *Rank attributes*
    - **Data and Storage resources**
      - *Input data, Storage Element (SE)*, где сохранять выходные данные, протоколы доступа к SE


```
[
JobType="Normal";
Executable = "gridTest";
StdError = "stderr.log";
StdOutput = "stdout.log";
InputSandbox = {"/home/mydir/test/gridTest"};
OutputSandbox = {"stderr.log", "stdout.log"};
InputData = {"lfn:/glite/myvo/mylfn" };
DataAccessProtocol = "gridftp";
Requirements = other.GlueHostOperatingSystemNameOpSys
    == "LINUX"
        && other.GlueCEStateFreeCPUs>=4;
Rank = other.GlueCEPolicyMaxCPUtime;
]
```

- If something goes wrong, the WMS tries to **reschedule and resubmit** the job (possibly on a different resource satisfying all the requirements)
- **Maximum number of resubmissions:**  
 **$\min(\text{RetryCount}, \text{MaxRetryCount})$** 
  - **RetryCount:** JDL attribute
  - **MaxRetryCount:** attribute in the “RB” configuration file

- **Service representing a computing resource**
- **Main functionality: job management**
  - Run jobs
  - Cancel jobs
  - Suspend and resume jobs
  - Provide info on “quality of service”
    - How many resources match the job requirements ?
    - What is the estimated time to have the job starting its execution ?
    - ...
  - ...
- **Used by the WM or by any other client (e.g. end-user)**
- **CE architecture accommodated to support both push and pull model**
  - Push model: the job is pushed to the CE by the WM
  - Pull model: the CE asks the WM for jobs
- **These two models are somewhat mirrored in the resource information flow**
  - In order to 'pull' a job a resource must choose where to 'push' information about itself



# CE Architecture







- Normal
- DAG - Directed Acyclic Graphs (DAG)
- MPICH - Message Passing Interface
- Checkpointable Jobs
- Partitionable
- Interactive Jobs
- Collection
- Parametric

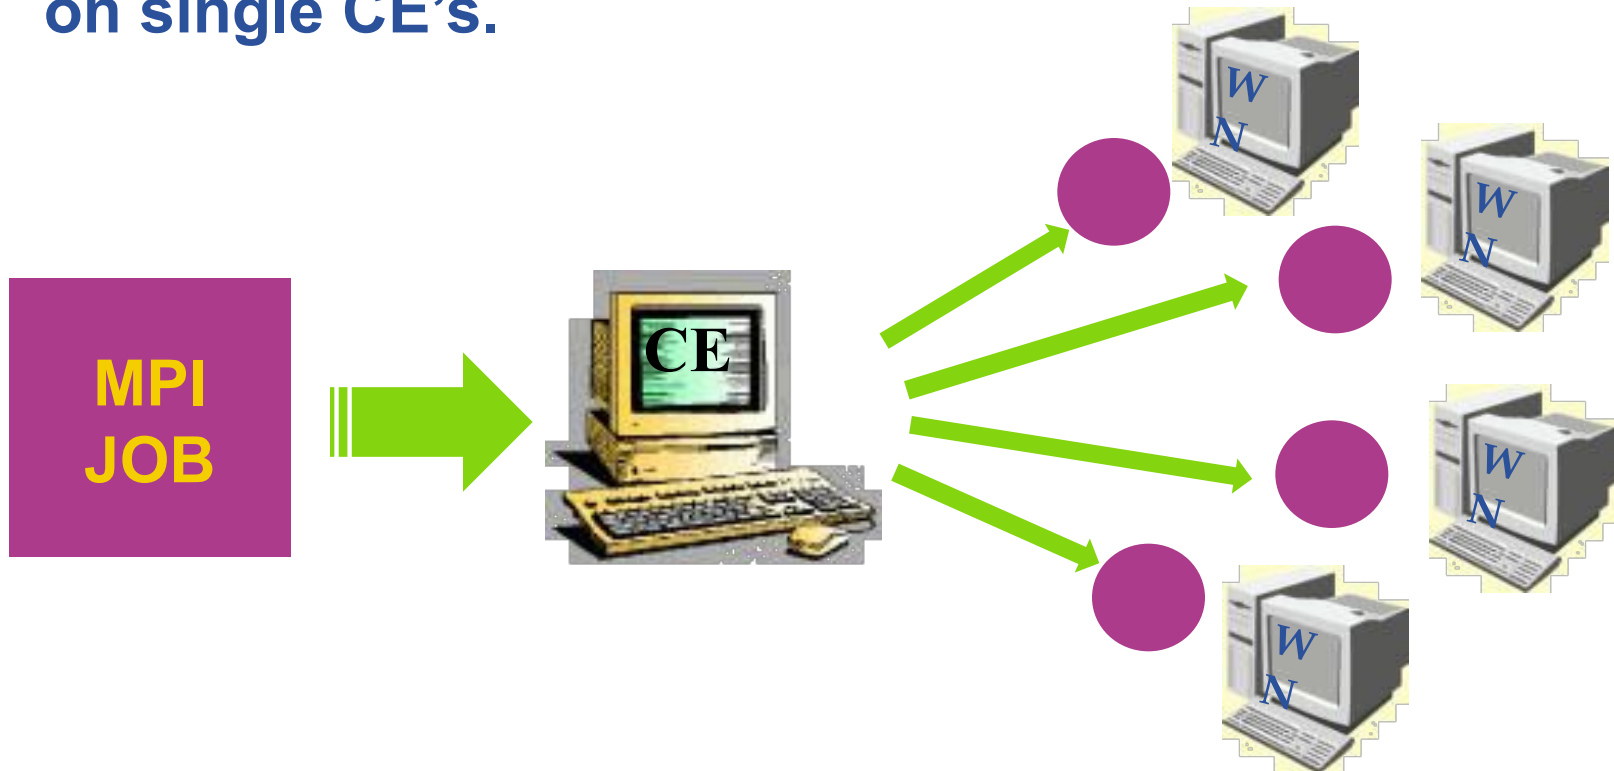
- A DAG represents a set of jobs:

*Nodes = Jobs*

*Edges = Dependencies*



- The MPI job is run in parallel on several processors.
- Libraries supported for parallel jobs: MPICH.
- Currently, execution of parallel jobs is supported only on single CE's.



- Type = “job”;
- JobType = “**MPICH**”;
- Executable = “...”;
- NodeNumber = “**int > 1**”;
- Argument = “...”;
- Requirements =
  - Member(“MpiCH”, other.GlueHostApplicationSoftwareRunTimeEnvironment)
  - && other.GlueCEInfoTotalCPUs >= NodeNumber ;
- Rank = *other.GlueCEStateFreeCPUs*;

➔ *Mandatory*

➔ *Mandatory*

➔ *Mandatory*

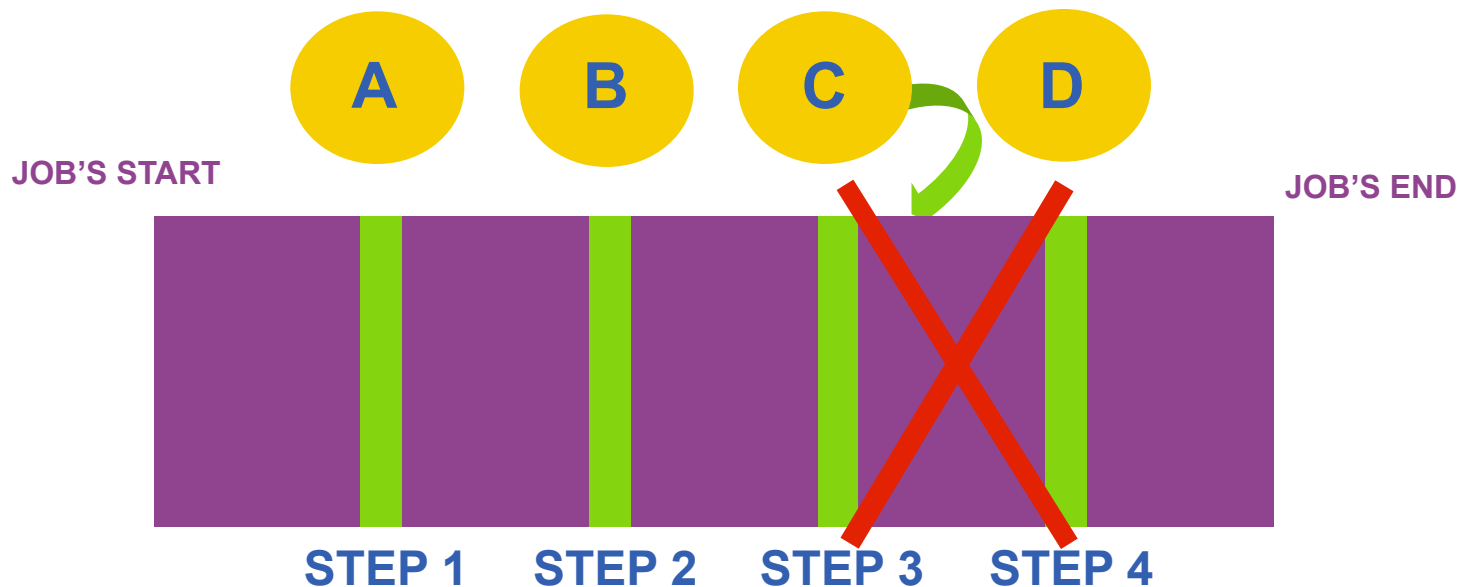
➔ *Mandatory*









➔ *Optional*

➔ *Mandatory*

➔ *Mandatory*


- It is a job that can be decomposed in several steps;
- In every step the job state can be saved in the LB and retrieved later in case of failures;
- The job can start running from a previously saved state instead from the beginning again.



- `Type = "job";`  *Mandatory*
- `JobType = "checkpointable";`  *Mandatory*
- `Executable = "...";`  *Mandatory*
- `JobSteps = "list int | list string";`  *Mandatory*
- `CurrentStep = "int >= 0";`  *Mandatory*
- `Argument = "...";`  *Optional*
- `Requirements = "...";`  *Optional*
- `Rank = "";`  *Optional*

- **JobType = “Interactive”**
- **When an interactive job is executed, a window for the stdin, stdout, stderr streams is opened**
  - Possibility to send the stdin to the job
  - Possibility to have the stderr and stdout of the job when it is running





- `JobType=Partitionable`
- `JobSteps = {"cms0", "cms1", "cms2", "cms3", "orca"};`
- `StepWeight = {7.5, 25, 37.5, 15, 15};`
- `CurrentStep = 0;`



```
JobType = "Parametric";
  Executable = "cms_sim.exe";
  StdInput = "input_PARAM_.txt";
  StdOutput = "myoutput_PARAM_.txt";
  StdError = "myerror_PARAM_.txt";
  Parameters = 10000;
  ParameterStart = 1000;
  ParameterStep = 10;
  InputSandbox = {
"file:///home/cms/cms_sim.exe",
"file:///home/cms/data/input_PARAM_.txt "
};
  OutputSandbox = {
"myoutput_PARAM_.txt",
"myerror_PARAM_.txt" };
  Requirements = other.GlueCEInfoTotalCPUs > 2;
  Rank = other.GlueCEStateFreeCPUs;
```