

Grid Data Management Services

D. Talia - UNICAL

Griglie e Sistemi di Elaborazione Ubiqui

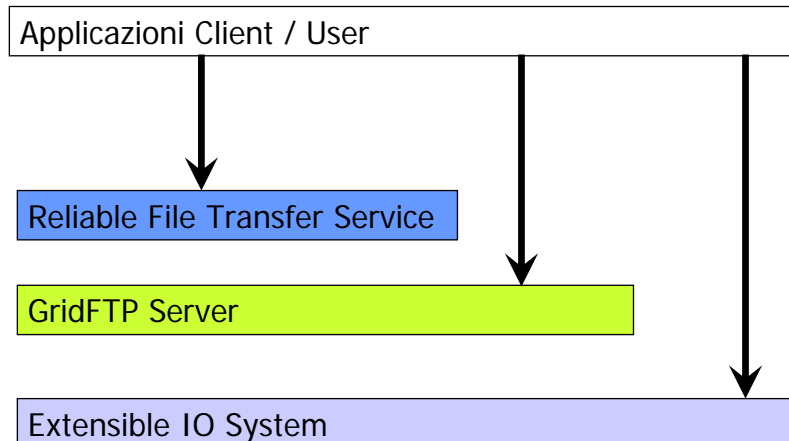
Sommario

- Grid Data Management
 - ◆ GridFTP
 - ◆ RFT
 - ◆ RLS
 - ◆ OGSA-DAI

GT4 Data Services

- GridFTP
 - ◆ High-performance Data transfer protocol
- The Reliable File Transfer Service (RFT)
 - ◆ Servizi di trasferimento di dati in GT4
- The Replica Location Service (RLS)
 - ◆ Registry Distribuito per gestire copie di dati
- Data Access and Integration Service (OGSA-DAI)
 - ◆ Servizi di accesso a databases relazionali e XML

Data Transport in Globus



Cosa è GridFTP?

- Un protocollo di data transfer sicuro, robusto, efficiente, standard.
- Un Protocollo
 - ◆ Più implementazioni indipendenti possono interoperare
- Il Globus Toolkit fornisce una implementazione di riferimento:
 - ◆ Server
 - ◆ Strumenti Client (globus-url-copy)
 - ◆ Librerie

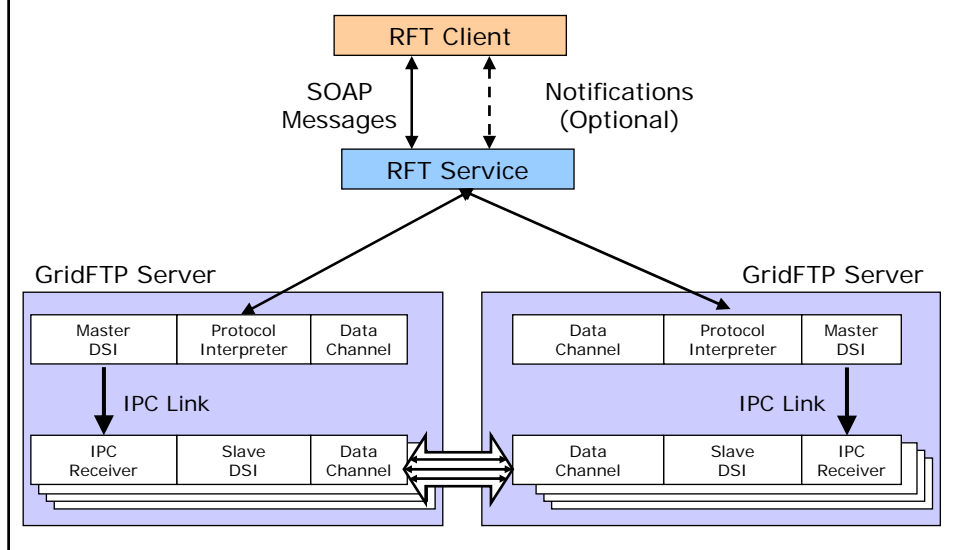
GT4 GridFTP: Implementazione

- Basato sulla libreria XIO (eXtensible Input/Output)
 - ◆ Definisce funzioni standard: Read/Write/Open/Close
- Molto modulare per permettere l'integrazione con una varietà di sorgenti data sources (files, mass stores, etc.)
- Implementa lo striping
- Include supporto per IPV6

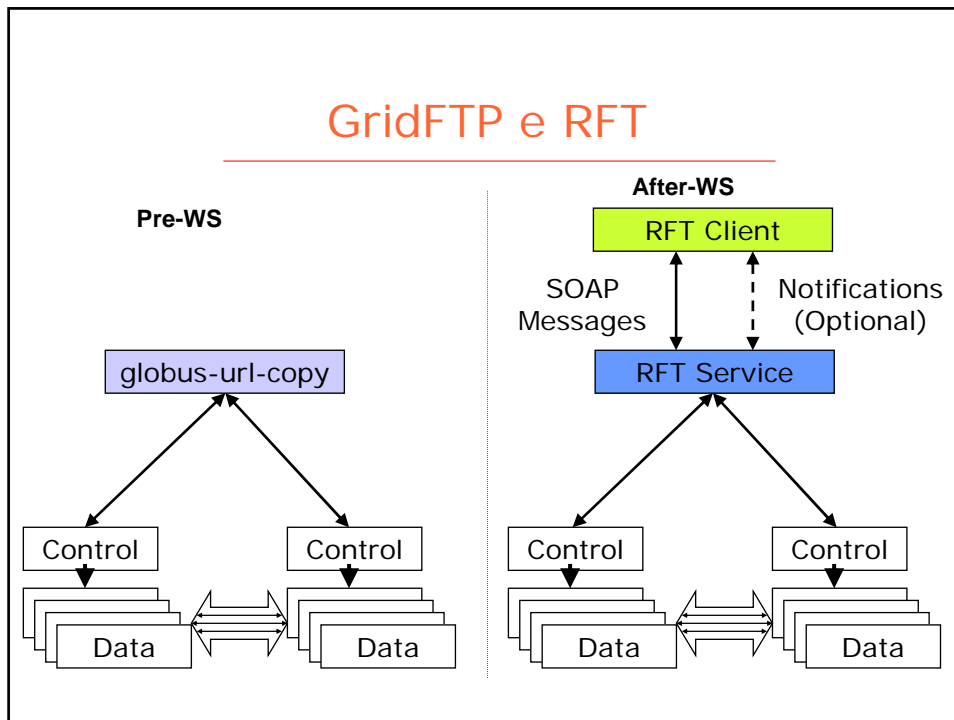
RFT: Reliable File Transfer Service

- Servizio di trasferimento dati ad alte prestazioni WS-RF compliant e Fault-tolerant.
 - ◆ Notifications/Query
- Affidabilità sulle alte prestazioni fornite da GridFTP
 - ◆ Integrated Automatic Failure Recovery
 - Network level failures.
 - System level failures.
 - ◆ Uno scheduler per trasferimento di dati con una politica FIFO di gestione della coda.

RFT: Reliable File Transfer



GridFTP e RFT



Gestione di Repliche nelle Grid

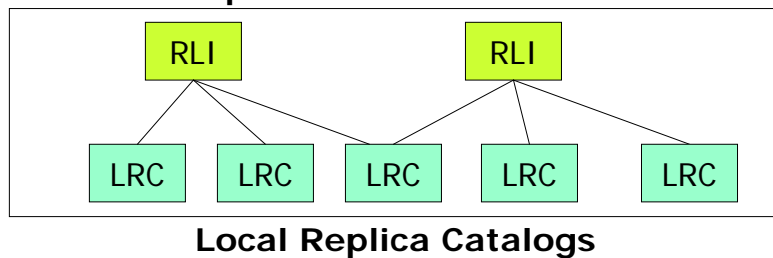
- Applicazioni data intensive producono terabytes o petabytes di dati
 - ◆ Quantità enormi di dati da gestire
- La replicazione di dati in più locazioni è utile per:
 - ◆ Fault tolerance
 - Evitare "single points of failure"
 - ◆ Performance
 - Evitare grandi latenze di trasferimento
 - Bilanciare il carico tra i nodi.

Replica Location Service

- **Un Replica Location Service (RLS)** è un registry distribuito che memorizza copie di dati e gestisce la scoperta di repliche
 - ◆ RLS mantiene i mapping tra gli identificatori *logici* e i *target names* (locazioni dei dati replicati)
 - ◆ Deve essere scalabile: supportare milioni di oggetti, centinaia di client
- RLS è un componente del Replica Management system di Globus
 - ◆ Insieme ai consistency services, replica selection services, reliable file transfer, ecc.

Replica Location Service


Replica Location Indexes



- Gli LRC contengono informazioni consistenti sui mapping "logical id -> -target" in un nodo
- I nodi RLI aggregano le informazioni relative agli LRC
- La gerarchia RLI può avere diversi livelli.

RLS senza Ridondanza


Replica Location Indexes



Local Replica Catalogs

RLS con Ridondanza

Replica Location Indexes



Local Replica Catalogs

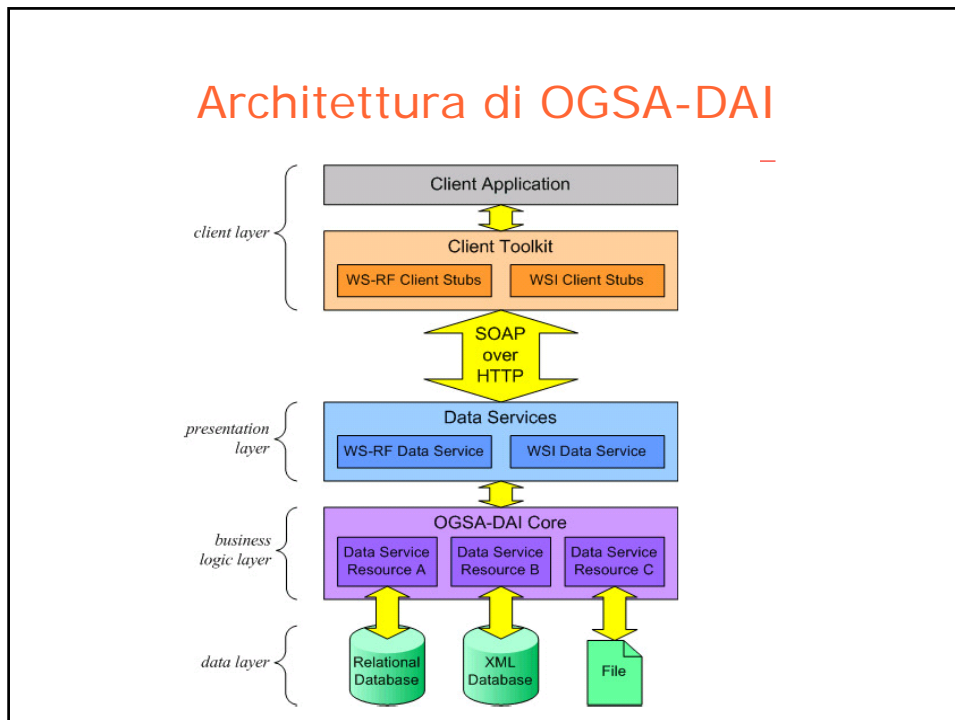
Obiettivi di OGSA-DAI

- Un modello per l'accesso integrato a database XML e relazionali:
 - ◆ Interfaccia consistente a database su Grid
 - ◆ Integrazione con diversi DBMS (Oracle, DB2, MySQL, PostgreSQL, SQL Server ...)
- Una base per sviluppare servizi di più alto livello
 - ◆ Data federation
 - ◆ Distributed query processing
 - ◆ Data mining
 - ◆ Data visualisation

Obiettivi di OGSA-DAI


- Definizione e sviluppo di Grid data services che forniscano accesso integrato a dati in databases e la loro gestione in ambiente distribuito.
- Include
 - ◆ Relational e object databases
 - ◆ XML databases e repositories
 - ◆ Collezione di files con descrizione (es: OMIM, SWISSPROT).

Architettura di OGSA-DAI



Interfaccia verso i DBs in OGSA-DAI

- Ogni Data Service Resource ha il proprio Data Resource Accessor che controlla l'accesso ad un database.
- OGSA-DAI include Data Resource Accessors per relational databases, XML databases e file systems. (Altri possono essere definiti!)



OGSA-DAI: Esempio di Uso

