

## Test e risultati sull'uso di un file system GPFS condiviso su rete WAN

Antonio Budano (INFN – Sezione di Roma 3)

In collaborazione con:

Vladimir Sapunenko (INFN - CNAF)

Elisabetta Vilucchi (INFN –LNF)

# Sommario

- ▣ Introduzione
- ▣ Caratteristiche di GPFS di IBM
- ▣ Descrizione dell'architettura
- ▣ Test e risultati
- ▣ Conclusioni

# Introduzione

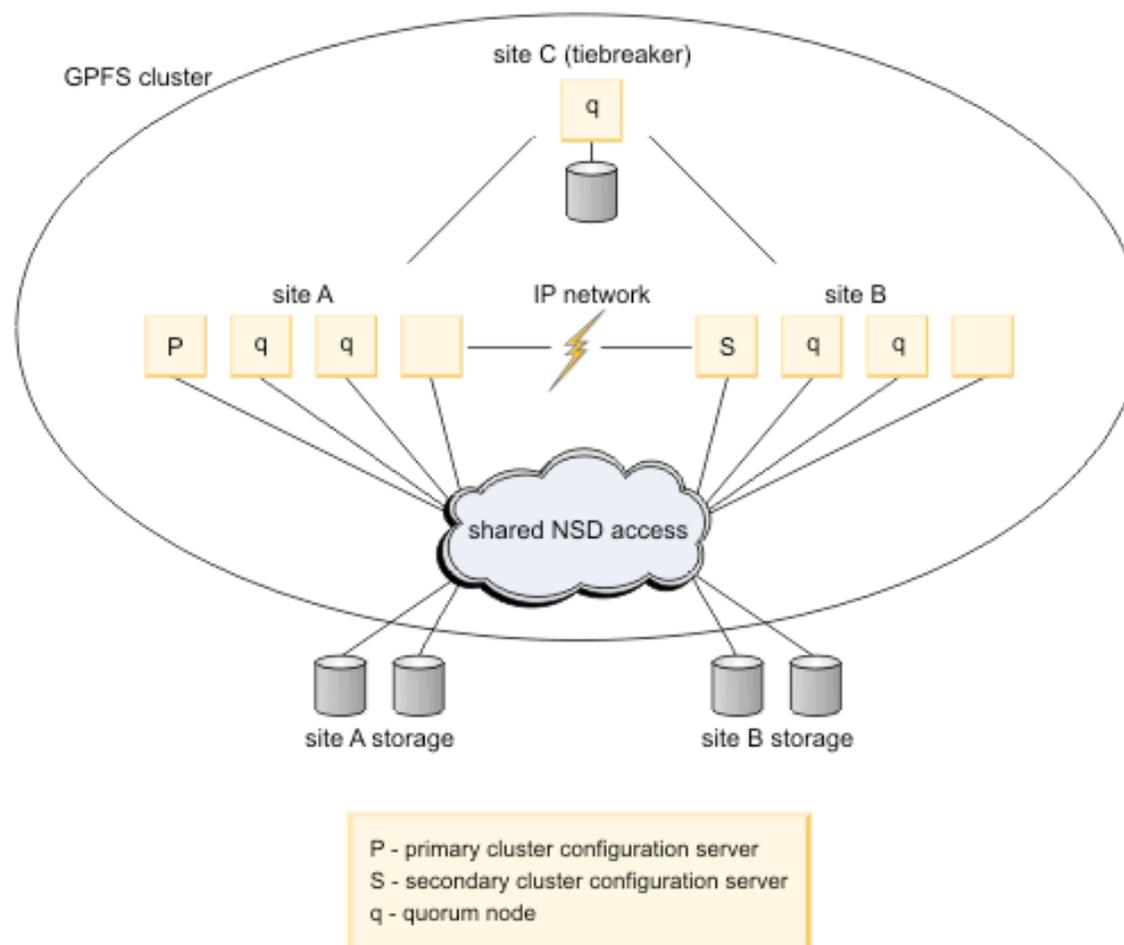
- L'idea di realizzare questa infrastruttura nasce nell'ambito del gruppo di lavoro dedicato a problematiche di Disaster Recovery.
- Necessità di poter avere un'area dove archiviare dati che sia affidabile e che contemporaneamente abbia delle performance sufficienti per le applicazioni che ne fanno uso come portali web, database e server virtuali.
- Abbiamo pensato ad un file system distribuito su rete WAN tra diverse sedi INFN.

# Caratteristiche di GPFS (1/3)

- ▣ Perché GPFS?
  - ▣ GPFS (General Parallel File System) di IBM offre molte feature che permettono di facilitare l'implementazione di sistemi in alta affidabilità contro i guasti "catastrofici" sia hardware sia software
  - ▣ la possibilità di effettuare **repliche** dei dati in file system geograficamente separati
  - ▣ La possibilità di poter utilizzare funzioni di **Snapshot**
  - ▣ **AFM (Active File Management)** che permette di condividere i dati in maniera asincrona (adatto ad esempio per reti con alto valore di latenza) tra diversi cluster GPFS.

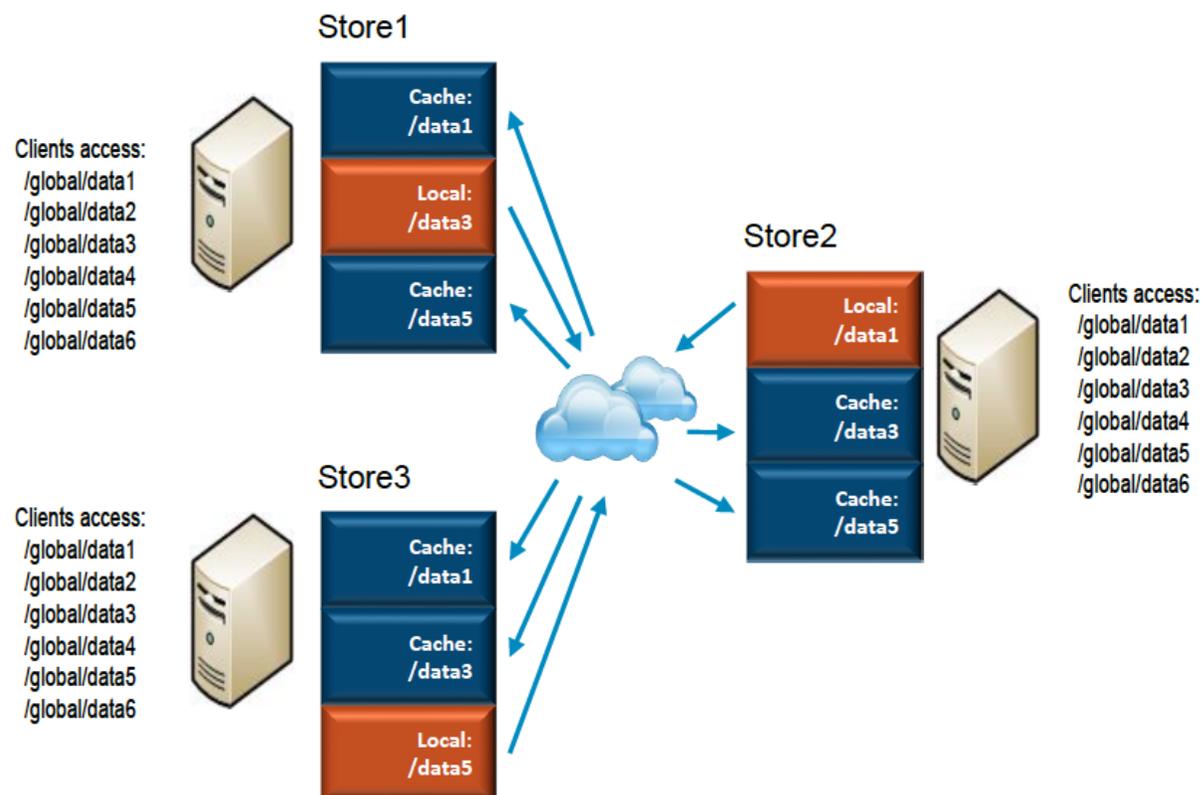
## Caratteristiche di GPFS (2/3)

- GPFS permette di configurare il numero di copie di Dati e Metadati sui diversi storage presenti nel cluster. Questa caratteristica può essere usata per creare un synchronous mirroring tra coppie di siti geograficamente separati.

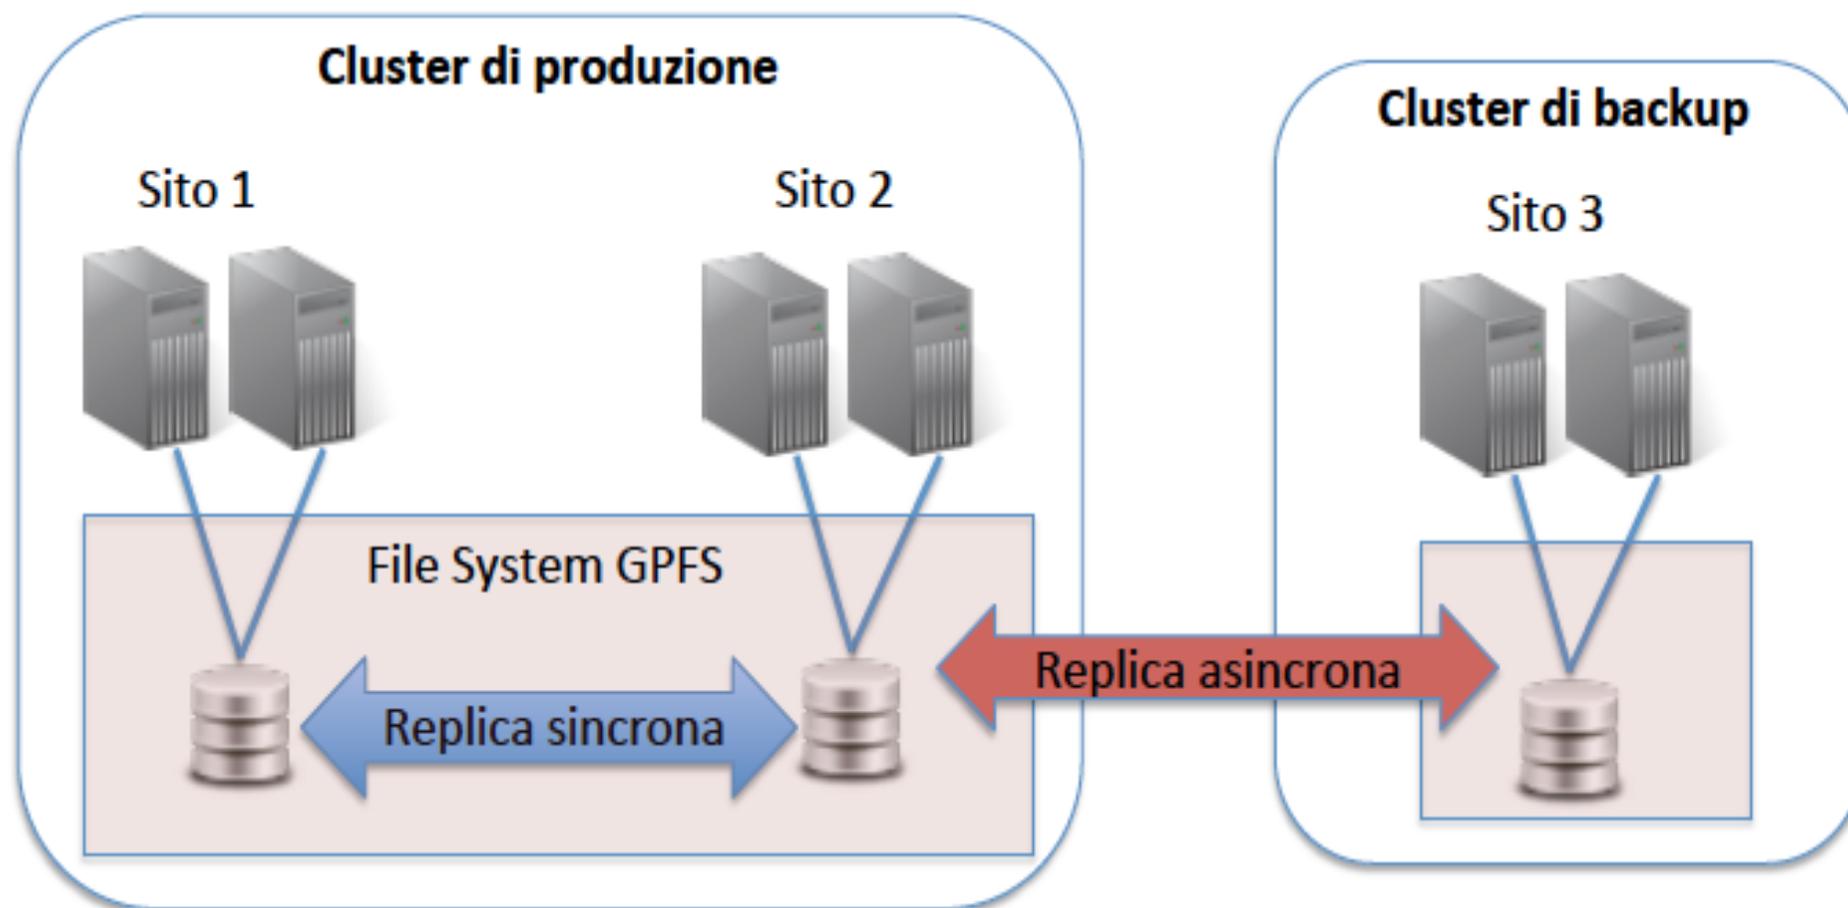


# Caratteristiche di GPFS (3/3)

- Può essere utilizzata per creare global namespace tra diversi data center.
- AFM è pensato per permettere un efficiente trasferimento dati su rete WAN.
- Il trasferimento tra home -> cache può avvenire in parallelo tra i nodi



# Architettura



# Cluster di Produzione (1)

- ▣ CNAF – ROMA3
  - ▣ Bandwidth 1 Gbit/s, RTT=6ms
  - ▣ 2 servers + 2TB di storage in ogni sito
  - ▣ Scrittura Sincrona

**Il parametro “read Replica Policy” permette di poter effettuare la lettura direttamente sui dischi locali (se disponibili).**

- ▣ Test effettuati:
  - ▣ Scrittura e lettura sequenziale e Random utilizzando il pacchetto “iozone”
  - ▣ Simulazione della rottura di uno dei due siti (disabilitando la porta ethernet nel server remoto) durante la scrittura di dati.
  - ▣ Simulazione della rottura del sistema di storage (disabilitando le porte Fiber Channel del sistema di storage) durante la scrittura di dati.
  - ▣ Utilizzando le applicazioni e i servizi del Sistema Informativo (portali web, database Oracle) residenti in Virtual Machine (KVM).

# Risultati ed Osservazioni (1)

	Scrittura sequenziale 1MB blocks (MB/s)	Lettura sequenziale 1MB blocks (MB/s)	Scrittura Random 1MB blocks (MB/s)	Lettura Random 1MB blocks (MB/s)
Disco locale Roma 3	168	160	160	84
Disco locale CNAF	164	176	160	64
Replica del FS, da Roma3	51	168	74	55
Replica del FS dal CNAF	108	196	90	90

- Performance nella scrittura sequenziale sono limitate dalla bandwidth
- Lettura le performances sono limitate dal disco locale
- Scrittura e lettura Random limitazioni dovute alla latenza (RTT) tra i siti

# Simulazioni di guasti

- Simulazione della rottura di uno dei due siti (disabilitando la porta ethernet nel server remoto) durante la scrittura di dati.
- Simulazione della rottura del sistema di storage (disabilitando le porte Fiber Channel del sistema di storage) durante la scrittura di dati.
- Osservazioni:
  - Fallimento di un sito durante una scrittura il tempo di ripristino dipende dalla configurazione del cluster che di default sono circa 60 s.
  - Tempo di recupero nel caso di fallimento del solo sistema di storage in uno dei due siti risulta pressoché immediato.

## Cluster di Produzione (2)

- ▣ LNF – ROMA3:
  - ▣ Bandwidth tra Roma3 e Tier2 LNF: 10 Gbit/s, RTT=0,6ms (Rete privata progetto Megalab)
  - ▣ 2 servers + 2TB di storage in ogni sito
  - ▣ Scrittura Sincrona
  
- ▣ Test effettuati:
  - ▣ Scrittura e lettura sequenziale e Random utilizzando il pacchetto “lozone”

## Test e Risultati (2)

	Scrittura sequenziale 1MB blocks (MB/s)	Lettura sequenziale 1MB blocks (MB/s)	Scrittura Random 1MB blocks(MB/s)	Lettura Random 1MB blocks (MB/s)
Disco locale Roma 3	137	148	116	128
Disco locale LNF	118	390	118	384
Replica del FS, da Roma3	134	151	114	131
Replica del FS da LNF	118	382	115	378

- Le performances nella scrittura sul file system sono limitate dalla bandwidth tra i due siti.

# Configurazione finale

- Aggiunto poi al cluster di produzione (2) un nuovo cluster al CNAF collegato via AFM (Cluster di Backup):
  - Home (ROMA3) – Cache (CNAF)
  - ROMA3 sito AFM Gateway
  - ROMA3 in questa configurazione è il solo sito di collegamento tra i due cluster (gateway).
  
- Test effettuati
  - Utilizzo delle applicazioni e dei servizi del Sistema Informativo (portali web, database Oracle) residenti in Virtual Machine (KVM)
  - Esecuzione di applicazioni sul cluster di produzione e cluster di backup

# Conclusioni

- GPFS ci permette di realizzare una soluzione robusta di Disaster Recovery che contemporaneamente offre delle performance sufficienti alle nostre esigenze.
- La soluzione può garantire la continuità dei servizi: in caso di guasto ad uno dei due siti il sistema può essere ripristinato in pochi istanti
- Dal sito di backup (AFM) è possibile ripristinare il file system anche se entrambi i siti di produzione diventassero inaccessibili
- La possibilità di creare snapshot (ad esempio giornalieri) rende il sistema ancora più robusto:
  - è possibile, ad esempio, in caso di cancellazione accidentale di dati, ripristinare tutti i dati del file system a partire dagli snapshot precedenti.

# Il Gruppo DR dell'INFN

Coordinatore : Stefano Zani  
Componenti : Sandro Angius  
Massimo Donatelli  
Claudio Galli  
Guido Guizzunti  
Dael Maselli  
Massimo Pistoni  
Claudio Soprano  
Riccardo Veraldi  
Vladimir Sapunenko  
Stefano Bovina  
+ Collaborazione di :  
Nunzio Amanzi  
Antonio Budano  
Elisabetta Vilucchi  
Alessandro De Salvo  
(F.Sys. distribuiti)

## Aree di intervento

DNS {distribuito + geo-replica}  
MAILING {distribuito + mail relay }  
SISTEMA INFORMATIVO :  
Contabilità (CNAF)  
Portale Utente (CNAF)  
Gestione Presenze (CNAF)  
Documentale (CNAF) [new]  
Business Intelligence BI (CNAF)  
Protocollo (CNAF) [new]  
AAI + GODIVA (LNF)  
Stipendiale Sxgest2 (LNF) [old]  
Stipendiale Cezanne (LNF) [new]  
Protocollo (LNF) [old]  
Documentale (LNF) [old]  
Portale Unico (LNF) [new]

...

Ogni Target-IT INFN che sia considerabile  
«Core Business &/OR Mission Critical»