

GARR WS9

OpenSource per l'erogazione di servizi in alta disponibilità

Roma 17 giugno 2009

Mario Di Ture
Università degli Studi di Cassino
Centro di Ateneo per i Servizi Informatici



Programma

- **Cluster Linux per l'alta disponibilita'**
- **DRBD**
- **Linux-HA Heartbeat**

Tipi di cluster

Un cluster è un gruppo di computer collegati che, lavorando in stretta relazione sembrano, sotto molti aspetti, un unico computer. Esistono diversi tipi di cluster:

- **High performance**
- **Load balancing**
- **High availability**



Alta disponibilità e Clustering

- Tra i computer (**detti anche nodi**) del **Cluster** intercorre una relazione di trust
- Quando un computer si rompe, altri si fanno carico (**take over**) del suo lavoro
- L'operazione di take over normalmente riguarderà **l'indirizzo IP, i servizi**, ecc.
- Il clustering esaminato non riguarda le elevate performance ma la **continuità del servizio**
- E' impossibile raggiungere una disponibilità del **100%**

Misurare il fermo macchina (downtime*)

% Disponibilit�	Downtime per anno	Downtime per mese	Downtime per settimana
90%	36.5 giorni	72 ore	16.8 ore
95%	18.25 giorni	36 ore	8.4 ore
98%	7.30 giorni	14.4 ore	3.36 ore
99%	3.65 giorni	7.20 ore	1.68 ore
99.5%	1.83 giorni	3.60 ore	50.4 min
99.8%	17.52 ore	86.23 min	20.16 min
99.9% ("tre nove")	8.76 ore	43.2 min	10.1 min
99.95%	4.38 ore	21.56 min	5.04 min
99.99% ("quattro nove")	52.6 min	4.32 min	1.01 min
99.999% ("cinque nove")	5.26 min	25.9 sec	6.05 sec
99.9999% ("sei nove")	31.5 sec	2.59 sec	0.605 sec

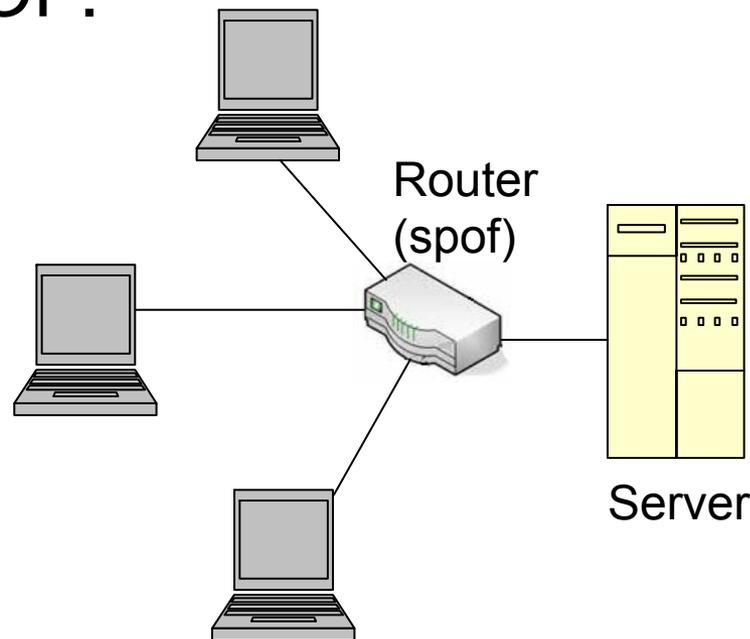
* I downtime possono essere **pianificati** (ad es. per l'applicazione di patch) o **non pianificati** (ad es. per la rottura di hardware)



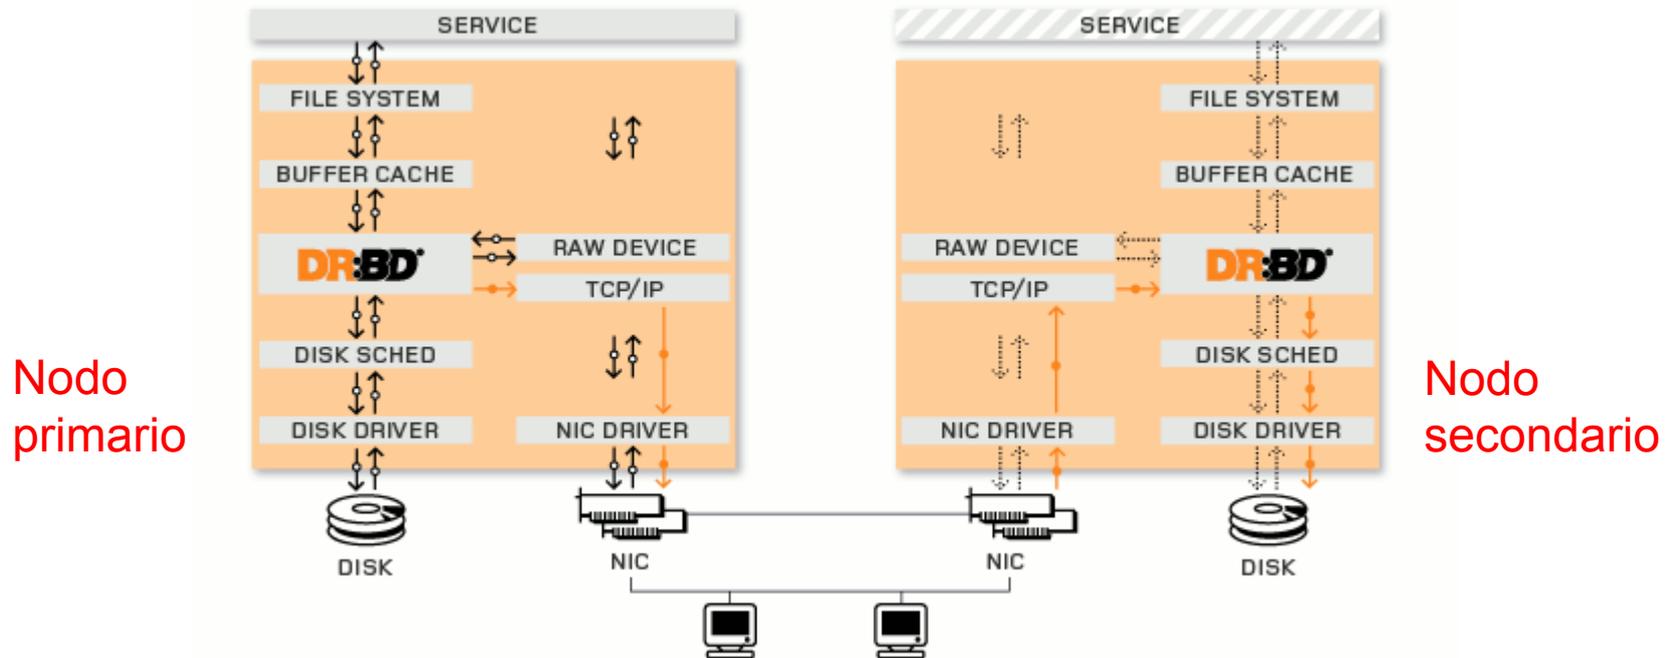
Single Point of Failure (SPOF)

E' importante eliminare o ridurre al minimo i single point of failure.

Per fare ciò si deve tendere a **ridondare** tutti gli attuali SPOF.



DRBD



DRBD sta per Distributed Replicated Block Device ed è, tipicamente, un componente di un cluster per la high availability (**modulo del kernel linux**). Effettua il mirror di un intero device a blocchi attraverso una connessione di rete. DRBD può essere visto come un raid-1 via rete.

DRBD – Configurazione e avvio

```
# Configurazione - file /etc/drbd.conf
# identico sui due host
global {
    usage-count yes;
}
common {
    protocol C;
    syncer { rate 5M; }
}
resource r0 {
    on nodo-a {
        device /dev/drbd1;
        disk /dev/hda5;
        address 192.168.0.1:7789;
        meta-disk internal;
    }
    on nodo-b {
        device /dev/drbd1;
        disk /dev/hda5;
        address 192.168.0.2:7789;
        meta-disk internal;
    }
}
```

```
# Su entrambi i nodi:
# Avvio drbd:
/etc/init.d/drbd start
# Elimino il fs preesistente (se necessario):
dd if=/dev/zero bs=1M count=1 of=/dev/hda5; sync
# Creo e collego la risorsa /dev/drbd1 (disk state: Diskless):
drbdadm create-md r0
# Collego il device e set della sincr. (disk state: Inconsistent):
drbdadm attach r0
drbdadm syncer r0
# Apro sul firewall dei nodi la porta tcp 7789.
# Peer connect (ds stato: Inconsistent/Inconsistent)
drbdadm connect r0
# Disattivo i servizi al boot: (esempio di un web server)
chkconfig httpd off
chkconfig mysqld off
# Attivo il servizio al boot:
chkconfig drbd on
```

```
# Solo sul nodo PRIMARIO:
drbdadm -- --overwrite-data-of-peer primary r0
# Ora DRBD è operativo
# Creo il File System
mkfs.ext3 /dev/drbd1
mkdir /ha
mount /dev/drbd1 /ha
```

DRBD - meta-dati

DRBD memorizza alcune informazioni relative ai dati-utente replicati in un'area dedicata. Tali informazioni prendono il nome di meta-dati e possono essere allocate sullo stesso device o su un device esterno.

DRBD Metadata Size

Block device size	DRBD metadata
1 GB	2 MB
100 GB	5 MB
1 TB	33 MB
4 TB	128 MB

Calcolo approssimato dello spazio occupato dai meta-dati:

(C_{MB} = dimensione del device)

$$M_{MB} < \frac{C_{MB}}{32768} + 1$$

DRBD – Utilizzo *

I 10 nodi con i device più grandi:**

Device size [GB]	Data creazione
21.419,6953	2008-09-15
20.362,9516	2008-11-21
20.352,9548	2008-11-20
20.275,2031	2008-12-04
20.275,2031	2008-11-30
17.602,4477	2008-08-14
17.602,4477	2008-08-14
16.384,0000	2009-04-07
16.384,0000	2009-03-13
16.000,0000	2007-11-20

Nodi e risorse:

Numero di nodi installati	47.968
Numero di risorse configurate	75.362
Numero massimo di risorse su un nodo	185

* Fonte: http://usage.drbd.org/cgi-bin/show_usage.pl - Dati al 7/5/2009.

** Per le versioni open source antecedenti la 8.3 vengono supportati complessivamente device fino a 4 TB per nodo. La versione 8.3 supporta device fino a 16TB.

Spostare i dati sul device DRBD

Esempio: Web server Apache

```
mkdir /ha/http
cp /etc/httpd/conf/httpd.conf /ha/http/
/etc/init.d/httpd stop
ln -s -f /ha/http/httpd.conf /etc/httpd/conf/
cp -R /var/www/html /ha/http/htdocs
vi /etc/httpd/conf/httpd.conf
    DocumentRoot "/ha/http/htdocs"
chown -R apache.apache /ha/http
/etc/init.d/httpd start
```

Comandi da eseguire sul nodo primario

Comandi da eseguire su entrambi i nodi

Spostare i dati sul device DRBD

Esempio: Database server Mysql

```
/etc/init.d/mysqld stop
```

```
mkdir /ha/mysql
```

```
cp /etc/my.cnf /ha/mysql
```

```
ln -s -f /ha/mysql/my.cnf  
/etc/my.cnf
```

```
cp -R /var/lib/mysql
```

```
/ha/mysql/data
```

```
vi /etc/my.cnf
```

```
    datadir = /ha/mysql/data
```

```
chown -R mysql:mysql
```

```
/ha/mysql/data
```

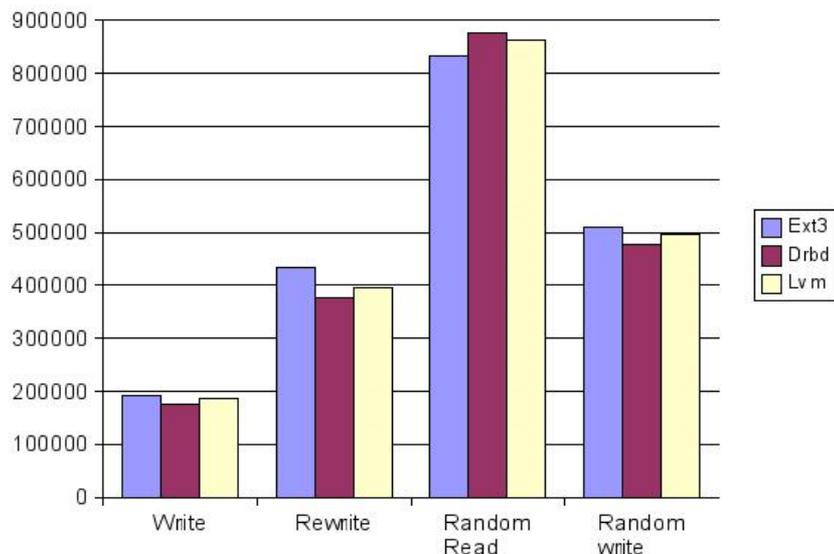
```
/etc/init.d/mysqld start
```

Comandi da eseguire sul nodo primario

Comandi da eseguire su entrambi i nodi

Performance dei device - iozone

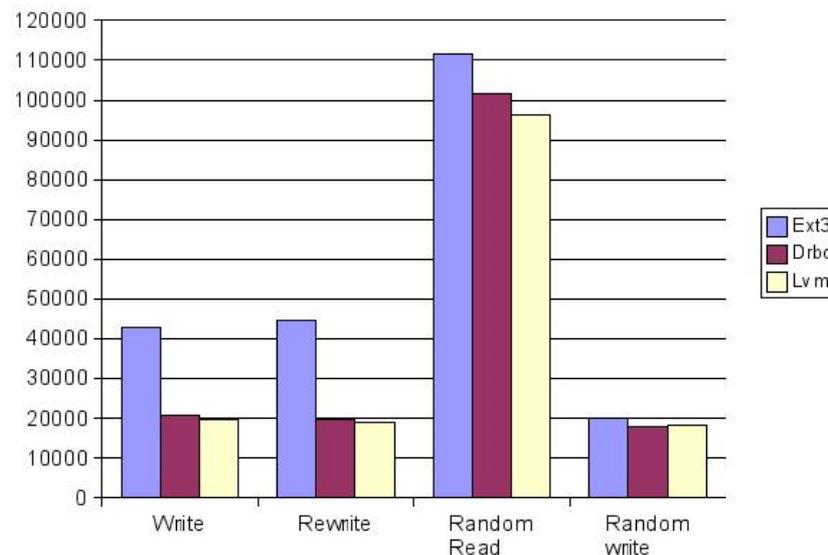
Prestazioni in cache



Ext3

*Ext3+DRBD**Ext3+DRBD+LVM*

Prestazioni fuori cache

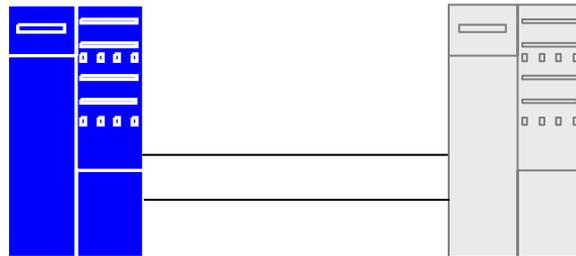


Fonte: <http://www.ba.infn.it/calcolo/documenti/Cluster.html>

Linux HA HighAvailability

Il ruolo normale di Linux HA è quello di:

- monitorare i nodi costantemente
- monitorare, tipicamente, utilizzando connessioni ridondanti
- attivare, ad esempio, un nodo inattivo quando un nodo che dovrebbe essere attivo non è più raggiungibile



Linux HA – Configurazione R1 (Obsoleta)

Dopo aver installato il sw creare sui due nodi:

1. l'utente hacluster e relativo gruppo haclient
2. il file /etc/ha.d/ha.cf
3. il file /etc/ha.d/authkeys (chmod 600)
4. il file /etc/ha.d/haresources

```
# /etc/ha.d/ha.cf
udpport 694
bcast eth0
node nodo-a nodo-b
ping 10.10.0.1 10.10.0.2
keepalive 4
deadtime 10
initdead 15
```

```
# /etc/ha.d/authkeys
auth 2
1 crc
2 sha1 MySecret
3 md5 MySecret
```

```
# /etc/ha.d/haresources
nodo-a 192.168.0.3 drbddisk::r0 Filesystem::/dev/drbd1::/ha httpd mysqld
```

5. Avviare il servizio: /etc/init.d/heartbeat start

Linux HA – Configurazione R2

1. Attivare crm in ha.cf (aggiungere direttiva **crm yes**).
2. Attivare l'interfaccia grafica e avviare il programma **hb_gui** (gui)
3. In hb_gui creare un **gruppo di risorse**, aggiungere al gruppo **IPAddr, Drbddisk, FileSystem, Mysqld e Httpd**. Avviare il gruppo di risorse
4. Creare un constraint **location** per il nodo destinato ad ospitare il gruppo di risorse
5. Associare alla location una espressione in cui **uname=nodo-a**
6. Tutte le impostazioni sulle risorse e sul constraint vengono salvate nel file **cib.xml**

Linux-HA Gui – Esempio 1

The screenshot shows the Linux HA Management Client interface. The main window displays a tree view of the configuration on the left and a detailed view of the selected resource on the right.

Tree View (Left Panel):

Name	Status
linux-ha	with quorum
Nodes	
10.10.0.2	ping node
10.10.0.1	ping node
nodo-b	running(dc)
nodo-a	running
Resources	
group_web	group
resource_ip	running on [nodo-a]
resource_drbd	running on [nodo-a]
resource_filesystem	running on [nodo-a]
resource_mysql	running on [nodo-a]
resource_http	running on [nodo-a]
Constraints	
Locations	
location_nodo_preferito	
Orders	
Colocations	

Attributes (Right Panel):

ID: location_nodo_preferito Score: 100

Resource: group_web Boolean OP:

Expressions:

Attribute	Operation	Value
#uname	eq	nodo-a

Buttons: Add Expression, Delete Expression, Apply, Reset

Connected to 127.0.0.1

Linux-HA Gui - Es. 1- Monitoring

The screenshot displays the Linux HA Management Client interface. The main window shows a tree view of the configuration, including Nodes (10.10.0.2, 10.10.0.1, nodo-b, nodo-a) and Resources (group_web, resource_ip, resource_drbd, resource_filesystem, resource_mysql, resource_http). A dialog box titled 'Add Operation' is open, showing the configuration for a 'monitor' operation.

Add Operation Dialog Configuration:

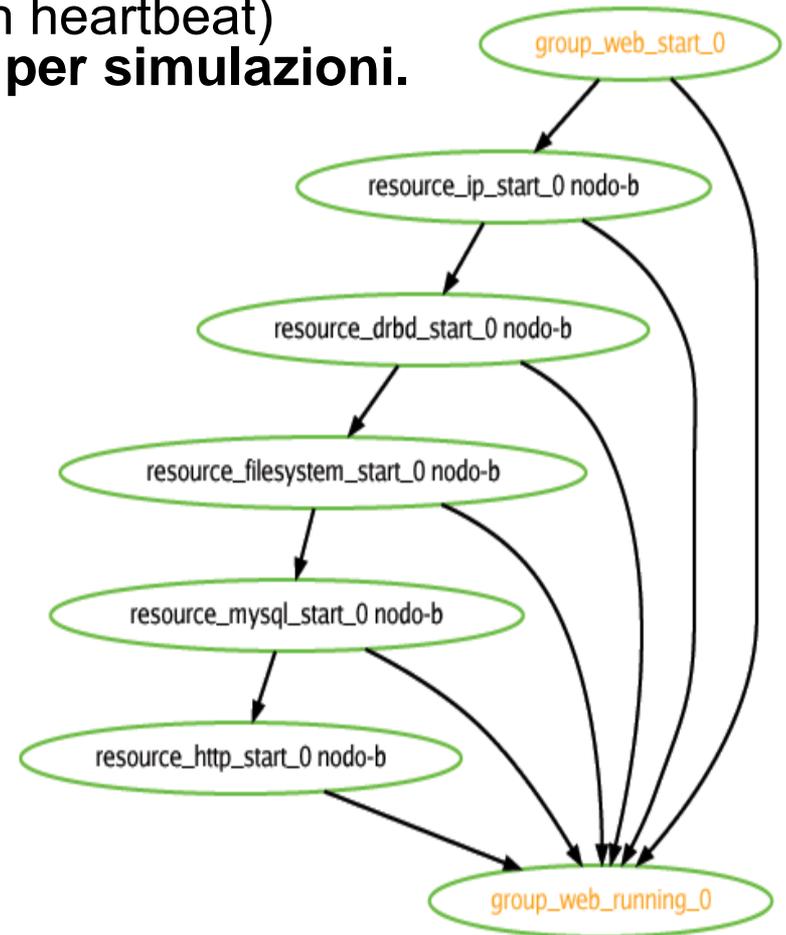
- Name: monitor
- Description: Monitoring-Http
- Interval: 15
- Timeout: 15
- Start Delay: 15
- Disabled: false
- Role: Started
- Prereq: nothing
- On Fail: restart

The dialog box also includes 'OK' and 'Cancel' buttons. The main window has 'Add Operation' and 'Delete Operation' buttons at the bottom right, and 'Apply' and 'Reset' buttons below them. The status bar at the bottom indicates 'Connected to 127.0.0.1'.

Linux-HA – Schema transizioni

Viene utilizzato il comando **ptest** (incluso in heartbeat) e graphviz per l'output grafico. Utile **anche per simulazioni**.

- Le frecce indicano l'ordine delle dipendenze
- Le azioni con bordo verde e testo nero sono transizioni effettive
- Le azioni con bordo verde e testo arancio sono pseudo azioni col solo scopo di semplificare il grafico
- Le azioni con testo nero vengono inviate al LRM
- I loop dipendono da errori di implementazione del cluster o bug di heartbeat.



In pratica:

```

cibadmin -Q | grep -v lrm > /tmp/hostname.xml
ptest -D /tmp/hostname.dot -X /tmp/hostname.xml
dot -Tpdf -o /tmp/hostname.pdf /tmp/hostname.dot
  
```

Linux-HA Gui

Mail Server

The screenshot displays the Linux HA Management Client interface. The window title is "Linux HA Management Client". The main area is divided into a left sidebar and a right pane. The sidebar shows a tree view of the configuration:

- linux-ha (with quorum)
 - Nodes
 - 10.10.0.5 (ping node)
 - nodo-b (running(dc))
 - nodo-a (running)
 - resource_drbdisk (running on [nodo-a])
 - resource_network_ha (running on [nodo-a])
 - resource_postfix (running on [nodo-a])
 - resource_mail (running on [nodo-a])
 - resource_filesystem (running on [nodo-a])
 - resource_cyrus (running on [nodo-a])
 - Resources
 - gruppo_posta_unicas (group)
 - resource_network_ha (running on [nodo-a])
 - resource_drbdisk (running on [nodo-a])
 - resource_filesystem (running on [nodo-a])
 - resource_cyrus (running on [nodo-a])
 - resource_postfix (running on [nodo-a])
 - resource_mail (running on [nodo-a])
 - Constraints
 - Locations
 - llocation_posta_unicas
 - Orders
 - Colocations

The right pane shows the "Informations" tab with the following configuration details:

- Version: 2.1.3
- Debug Level: 0
- UDP Port: 694
- Keep Alive: 4
- Warning Alive: 15000ms
- Dead Time: 30
- Initial Dead Time: 60

At the bottom of the right pane, there are three buttons: "Apply", "Reset", and "Default". The status bar at the bottom left indicates "Connected to 127.0.0.1".

Linux-HA e Fencing

- Ci possono essere situazioni in cui il software di gestione non è in grado di definire correttamente lo stato del cluster
- Il fencing è un metodo adottato per riportare lo stato del cluster alla “normalità”
- Il fencing ha lo scopo principale di evitare danni ai dati
- In pratica, nega l'accesso ad una risorsa (ad esempio ad un hard disk) ad un nodo se quest'ultimo perde il contatto con gli altri nodi
- Il fencing può avvenire a livello di risorsa o a livello di nodo
- **Stonith** (shoot the other node in the head) è il sistema di fencing di Heartbeat ed opera a livello di nodo facendo uso di device come iLO, power switch etc.

Grazie per l'attenzione

info: m.diture@unicas.it

Riferimenti:

www.linux-ha.org

www.drbd.org

www.ba.infn.it

www.clusterlabs.org