



Xen, Alta Affidabilità e Assegnazione Dinamica delle Risorse



Riccardo M. Cefalà
Mirko Mariotti
Leonello Servoli

Incontro di lavoro della CCR INFN
Laboratori Nazionali di Legnaro
10-11 Dicembre 2008

Introduzione: Il Sito INFNGrid di Perugia

- La Farm nasce dalla compartecipazione dei vari gruppi di ricerca e a partire dal 2004 è entrata a far parte di INFNGrid.
- Offre circa 200 CPU e 30TB di storage.
- Serve sia Utente Locale che GRID.





Introduzione: Virtualizzazione @ Perugia

Crescente Impiego della Virtualizzazione (Xen) nel sito INFNGrid Perugia e il Dipartimento di Fisica dell'Università degli Studi di Perugia:

- Maggiore offerta di Servizi risparmiando Risorse
- Gestione più semplice rispetto Hardware Reale
- Aspetti intrinseci di Alta Affidabilità & Disponibilità
- Possibilità di sviluppo di soluzioni ad-hoc



Introduzione: Virtualizzazione @ Perugia

Molti servizi offerti nella nostra Sezione, sono da tempo implementati con successo su VM (DomU); tra questi, i principali componenti GRID:

- Esempi: *CE*, *UI*, *SE*, *WN*

Nel passato sono state impiegate varie tipologie di Storage per le VM (DomU):

- iSCSI, ATA over Ethernet, Fibre Channel, NFS



Virtualizzazione @ Perugia

DomU Diskless

- Un ulteriore sviluppo per quanto riguarda i DomU, è stato quello di realizzare un sistema completamente diskless.
- Ciò rende possibile avere un DomU interamente caricato in RAM e slegato da ogni altro Vincolo.
- Molti servizi possono essere ospitati da queste macchine.



Virtualizzazione @ INFN Perugia

DomU Diskless

- La realizzazione è avvenuta avvalendosi del sistema di sviluppo di distribuzioni di Gentoo (Catalyst).
- Abbiamo realizzato degli Stage derivati da quelli usati per produrre *LiveCD*, opportunamente modificati per permetterne il boot via rete.
- Una volta creata la macchina siamo in grado di caricarla su un Dom0 remoto che accede a un Reposostory di VM Comune.



Domini non Privilegiati su Storage Condiviso

Abbiamo appurato che l'impiego di un repository di Immagini di DomU centralizzato offre diversi vantaggi:

- Le immagini sono disponibili presso tutti i Dom0 che accedono allo Storage.
- I servizi che le VM offrono sono indipendenti da guasti Hardware dei Singoli Dom0.
- Vi è un unico repository da mantenere.

E i Domini Privilegiati?

E' possibile applicare gli stessi principi ai Dom0?

- Similmente e unitamente ai DomU su Storage Centralizzato, fornire un'immagine generica di un Dom0 avviabile da rete significa che:


Ogni Macchina Disponibile può eseguire
Macchine Virtuali*

A tale scopo è stata sviluppata una metodologia
per l'esecuzione di Dom0 su NFS.

Dom0 via NFS

La realizzazione prevede l'impiego di:

- Un ambiente per il boot da rete (PXE, DHCP, TFTP, GRUB)
- Un filesystem di root su NFS
- Customizzazioni Varie



Dom0 via NFS (DHCP su Infolab)

- Configurazione standard per il boot via rete.

```
option space PXE;
option PXE.mtftp-ip                code 1 = ip-address;
option PXE.mtftp-cport             code 2 = unsigned integer 16;
option PXE.mtftp-sport             code 3 = unsigned integer 16;
option PXE.mtftp-tmout             code 4 = unsigned integer 8;
option PXE.mtftp-delay             code 5 = unsigned integer 8;
option PXE.discovery-control       code 6 = unsigned integer 8;
option PXE.discovery-mcast-addr    code 7 = ip-address;

class "pxeclients"
{
    match if substring (option vendor-class-identifier, 0, 9) = "PXEClient";
    option vendor-class-identifier "PXEClient";
    vendor-option-space PXE;

    option PXE.mtftp-ip 0.0.0.0;
}

option option-150 code 150 = text;
option option-128 code 128 = string;
option option-129 code 129 = text;
```

```
host post01 {
    next-server          192.168.0.100;
    hardware ethernet    00:11:2f:a8:b4:d4;
    fixed-address         192.168.0.101;
    filename              "pxegrub";
    option option-150     "/grub/post01.conf";
}
```



Dom0 via NFS (pxeGRUB)

- Il DHCP su virtdom fornirà i parametri di rete, il bootloader e il relativo file di configurazione.
- La seconda entry farà sì che il bootloader contatti il secondo TFTP server (virtdom)

```
default 0
timeout 2
password xxxxx

title    Infolab terminal
         root (nd)
         kernel /kernel/ltsp-2.6.17.8 rw root=/dev/ram0
         initrd /initrd/ltsp-2.6.17.8.gz

title    On-demand virtual machines
         password xxxxx
         dhcp
         tftpserver 192.168.0.5
         root (nd)
         configfile /grub/post01.conf
```



Dom0 via NFS (TFTP, NFS su virtdom)

- virtdom fornirà un secondo file di configurazione per pxeGRUB specificando il filesystem via NFS offerto da virtdom stesso

```
#virtdom exports
/opt/ondemand/root          192.168.0.0/255.255.255.0(ro,no_root_squash,async)
/opt/ondemand/imgs          192.168.0.0/255.255.255.0(rw,no_root_squash,async)
```

```
#post-pIV-realtek - NFS root
default 0
timeout 2
title    Dom0 - NFS
         root (nd)
         kernel /hypervisors/xen-3.1.gz dom0_mem=32M
         module /kernels/kernel-2.6.20-xen-r6-pIV-rltk ip=dhcp root=/dev/nfs \
         nfsroot=192.168.0.5:/opt/ondemand/root
```

- Il Kernel dei Dom0 deve supportare rootfs over NFS

Dom0 via NFS (NFS Root Filesystem)

- Il filesystem di root (Debian etch) deve essere opportunamente configurato.
- Condiviso => Read Only. E le porzioni *Read/Write* necessarie al funzionamento (es. `/var`)?
- Impieghiamo una tecnica tipica dei *sistemi embedded*:

I file che devono essere scrivibili vengono sostituiti da link simbolici nelle loro posizioni originali e spostati in una nuova posizione (`/flash`).

Ogni macchina creerà il tree delle locazioni scrivibili in RAM che verrà montato in `/flash` in fase di boot.



Dom0 via NFS (NFS Root Filesystem)

```
virtdom:~# ls -l /opt/ondemand/root/var/  
[...]  
drwxrwsr-x 2 root staff 4096 Oct 28 2006 local  
lrwxrwxrwx 1 root root 15 Nov 16 18:37 lock -> /flash/var/lock  
lrwxrwxrwx 1 root root 14 Nov 16 18:37 log -> /flash/var/log  
drwxrwsr-x 2 root mail 4096 Oct 29 15:59 mail  
drwxr-xr-x 2 root root 4096 Oct 29 15:59 opt  
lrwxrwxrwx 1 root root 14 Nov 16 13:06 run -> /flash/var/run  
drwxr-xr-x 3 root root 4096 Oct 29 16:01 spool  
drwxr-xr-x 3 root root 4096 Nov 16 09:42 xen
```

```
virtdom:~# ls -l /opt/ondemand/root/flash/*  
/opt/ondemand/root/flash/etc:  
total 4  
drwxr-xr-x 4 root root 4096 Nov 29 12:18 udev  
  
/opt/ondemand/root/flash/var:  
total 20  
drwxr-xr-x 5 root root 4096 Nov 26 10:59 lib  
drwxrwxrwt 2 root root 4096 Nov 16 13:07 lock  
drwxr-xr-x 5 root root 4096 Nov 16 12:56 log  
drwxr-xr-x 2 root root 4096 Nov 21 17:27 run  
drwxrwxrwt 2 root root 4096 Nov 23 16:37 tmp
```

```
post23:~# ls -al /flash/  
total 4  
drwxrwxrwt 4 root root 80 Jan 18 11:34 .  
drwxr-xr-x 20 root root 4096 Nov 26 09:46 ..  
drwxr-xr-x 4 root root 80 Jan 18 11:34 etc  
drwxr-xr-x 7 root root 140 Jan 18 11:34 var
```

Link consistenti sia in
chroot che sui Dom0.


Dom0 via NFS

(Modifiche agli script di Xen)

- Configurazione della rete di Xen 3.1:
 - `eth0` $\rightarrow$ `peth0`
 - Crea un'interfaccia virtuale `eth0` e assegna essa l'IP.
- Ciò causa l'interruzione della connessione NFS!
- E' quindi necessario modificare il comportamento di default.

In Xen 3.2 il meccanismo è stato modificato in modo simile e non costituisce più un problema.

Dom0 via NFS (Timeline)





Dom0 via NFS (Sviluppi Futuri & Riferimenti)

Prossimamente prevediamo di realizzare Dom0 completamente Diskless (Senza NFS).

Il nostro Howto è pubblicato sul Wiki di Xen:

<http://wiki.xensource.com/xenwiki/HowTos>


Xen Dom0 root filesystem over NFS Howto



Virtualizzazione @ Perugia: The Net Result

- Come in molte sedi, l'infrastruttura di rete a Perugia poggia sulla tecnologia VLAN.
- L'integrazione di tale tecnologia con la versatilità delle macchine virtuali permette la realizzazione di scenari dinamici e altamente configurabili
- Ad esempio:
 - Tutte le macchine del “*Laboratorio d'acquisizione dati*” possono diventare Dom0 su un segmento di rete da tutt'altra parte nell'edificio.

Virtualizzazione @ Perugia: The Net Result





Virtualizzazione @ Perugia: The Net Result

- Il Gateway nella figura precedente è un DomU diskless direttamente collegato alla dorsale VLAN che “natta” le varie reti locali (Wireless, Labs, etc.).
- In precedenza il compito era svolto da una macchina fisica. Il tempo di ripristino dopo un guasto è di ordini di grandezza superiore rispetto a rilanciare la stessa **Istanza Virtuale di Gateway** su un altro Dom0.

Gestione Dinamica delle VM (Introduzione)

- Gestire manualmente le VM diventa difficoltoso al crescere del numero.
- La Gestione Automatica delle VM apre la strada a nuove applicazioni per:
 - Ottimizzare l'impiego delle risorse
 - Risolvere problemi dovuti all'eterogeneità degli ambienti
 - Applicazioni di Alta Affidabilità e Disponibilità
 - La Semplificazione delle operazioni di Manutenzione

Gestione Dinamica delle VM (Prototipo Introduzione)

- Nell'ultimo anno è stato sviluppato un prototipo con lo scopo di automatizzare il processo di gestione delle VM
- L'applicazione deve essere flessibile e fornire strumenti per:
 - Definizione di classi di VM (**Ambienti**)
 - Monitoring delle **Risorse**
 - Controllo delle **Richieste** d'uso delle Risorse
 - Meccanismi di **Decisione** per la Gestione

Gestione Dinamica delle VM (Prototipo Architettura Generale)


- Applicazione Client-Server

- Gruppi di Client e Manager


- Indipendenza da Strutture esistenti

- Batch System

- RMS




Gestione Dinamica delle VM (Prototipo - Client)



- Raccolta informazioni sistema: *Proprietà*
- Comunicazione Proprietà
- Esecuzione comandi per conto del Manager
- Plugin Comandi e Estrazione Proprietà
 - Ampie possibilità di configurazione


Gestione Dinamica delle VM (Prototipo - Manager)

- Invio Richieste Proprietà ai Client
- Aggregazione
- Logica di Decisione Basata su **Eventi** e Proprietà
- Invio Comandi ai Client



Gestione Dinamica delle VM (Prototipo – Comunicazione)

- **Spread Toolkit:** Group Communication System
- Definizione di Protocolli a livello Applicazione
- Gestione Gruppi
 - Multicast e Point to Point
- Qualità del Servizio
 - Garanzia di Consegna
 - Ordinamento
 - Efficienza



Gestione Dinamica delle VM (Prototipo - Comunicazione)

Membership Messages

campi	MEMBERSHIP_MESSAGE	group	reason	extra
tipo	<i>Intero</i>	<i>Stringa</i>	<i>Intero</i>	<i>Stringa</i>
significato	<i>Id Messaggio</i>	<i>Nome Gruppo</i>	<i>Id. Evento</i>	<i>Nome Client</i>

Regular Messages


campi	REGULAR_MESSAGE	groups	message	msg_type	sender
tipo	<i>Intero</i>	<i>Lista</i>	<i>Stringa</i>	<i>Intero</i>	<i>Stringa</i>
significato	<i>Id Messaggio</i>	<i>Destinatari</i>	<i>"Payload"</i>	<i>Codice Mess.</i>	<i>Mittente</i>

- GETPROP, FETCHPROP
- EXECUTE
- CONTROL

- PROPVAL, PROPLIST, PROPERR
- EXECVAL, EXECERR
- CLB_CONTROL

Gestione Dinamica delle VM (Implementazione Client)


- Python
- Multithread
 - IFaceDaemon
 - ReaderDaemon
 - Runner




Esempio Proprietà:

```
[ram_free]
command = ram
parameters = MemFree
return_type = int
ticks = 60
```

Gestione Dinamica delle VM (Implementazione Manager)



- Python
- Multithread
 - Listener, Sender
 - TriggerWatch
- Trigger




**Esempio
Trigger:**


```
[client_query]
expr = { len(manager.clients) != 0 }
cmd = { sender.send_get_property() }
ticks = 30
on_update_check = no
```

Gestione Dinamica delle VM (Prototipo – Test Scalabilità 1)

- Il prototipo è stato testato in varie condizioni fino a **300 Client**, **1 Manager** e messaggi di **10 - 100Kb**




Manager CPU Load / Client (5min average)




Manager RAM Usage/Clients (5min average)

Gestione Dinamica delle VM (Prototipo – Test Scalabilità 2)




Instant Net Usage (100 Clients)



Manager Net Usage/Clients (5min average)


Gestione Dinamica delle VM (Esempio – Batch System)



Gestione Dinamica delle VM (Esempio – Batch System)

- Casi di Mutua Incompatibilità degli Ambienti:
 - Utente locale necessita di software di tipo ingegneristico distribuito solo per Debian (caso reale).
 - Incompatibilità tra il software in uso e nuovi Sistemi Operativi (Aggiornamento SLC3 → SLC4).

Gestione Dinamica delle VM (Esempio – Batch System)



Gestione Dinamica delle VM (Esempio – Alta Affidabilità)

- Precedenti esperimenti in Sezione hanno prodotto risultati riguardanti l'Alta Affidabilità.
- I Meccanismi di Gestione Dinamica delle VM possono integrare ulteriormente questi aspetti.

Gestione Dinamica delle VM (Esempio – Alta Affidabilità)

- Il Manager Conserva il *Timestamp* dell'ultimo messaggio ricevuto da ogni Client.
- Un Trigger configurato appositamente può eseguire automaticamente il Fail-Over di una VM se essa non risponde da troppo tempo.

```
[client_alive_check]
expr = { len(manager.groups["mailers"].values()) != 0 }
cmd = {
    from time import time
    for c in manager.groups["mailers"].values():
        d = time() - c.active_timestamp
        if (d > 120):
            print c.name, 'not active for more than 2 min!', d
    }
ticks = -1
on_update_check = yes
```

Gestione Dinamica delle VM (Conclusioni & Sviluppi Futuri)

- Altri test sono in programma per verificare la capacità di gestione degli Ambienti Virtuali e le Politiche di Decisione.
- Verranno definite Metriche di Valutazione per stabilire l'impatto sulle code nei batch system (Testbed già realizzato).
- Un prototipo completo verrà implementato nel sito INFNGrid di Perugia per l'inizio del 2009.

- Sono state mostrate le tecniche sviluppate sfruttando la Paravirtualizzazione (Xen):
 - DomU Diskless
 - DomU su Storage Centralizzato
 - Dom0 su NFS
 - Integrazione con la Rete Dipartimentale (VLAN)
 - Gestione Dinamica delle VM

- Attraverso le varie soluzioni è già possibile usufruire di un ambiente flessibile e che si adatta ad essere ulteriormente espanso. Nel prossimo futuro si prevede:
 - Consolidamento e Testing dell'Infrastruttura attuale
 - Realizzazione di Dom0 con rootFS in RAM
 - Realizzazione e Test di DomU su Filesystem Distribuiti
 - Lo studio di applicabilità di programmi già esistenti (*Ganeti* by *google.code*)



Contatti

- Leonello Servoli - leonello.servoli@pg.infn.it
- Mirko Mariotti - mirko.mariotti@fisica.unipg.it
- Riccardo M. Cefalà - riccardo.cefala@pg.infn.it



Links

INFN-Grid Perugia

- <http://grid.pg.infn.it>

Gentoo Catalyst

- <http://www.gentoo.org/proj/en/releng/catalyst/>

- Xen Wiki HowTos

- <http://wiki.xensource.com/xenwiki/HowTos>

Xen

- <http://www.xen.org>