Soluzioni Cluster per l'alta disponibilità dei servizi

Gorizia, 1 dicembre 2001

Overview

- Il problema della High Availability, o RAS
- Soluzioni basate su Linux
- Chi vi parla:
  Marino Miculan
  Docente di Sistemi Operativi
  Dipartimento di Matematica e Informatica,
  Università degli Studi di Udine
  `miculan@dimi.uniud.it`

Alcuni tipici scenari

- Servizi Internet
  - E-Commerce: il cliente deve essere soddisfatto
  - Home banking: transazioni rapide e sicure
  - Providers (Web hosting)
  - Proxy (caching di rete), DNS
  - E-Content providers (quotidiani on line…)
- Servizi Intranet/Extranet
  - Workflow/datamining aziendali
  - Chain Resource Management, SCM…

High Availability (Reliability, Availability, Serviceability)

- Disponibilità: 24x7, o "number of nines":
  - 99.9%: 8 ore 45 minuti all'anno
  - 99.99%: 52 minuti 36 secondi all'anno
  - 99.999%: 5 minuti 15 secondi all'anno
- Manutenibilità
  - Riconfigurazione, upgrade, diagnosi e risoluzione on line
- Scalabilità
  - aumentare graduatamente il sistema al crescere del carico
- Gestibilità
  - La complessità di gestione non deve crescere sensibilmente
- E che costi poco!

Una catalogazione dei sistemi di calcolo per disponibilità

1. Sistemi general-purpose
   PC, server interni non mission-critical…
2. Sistemi ad alta disponibilità e scalabilità
   Minori interruzioni possibili. Adattamento al carico.
   Server aziendali, mission-critical, banche, telecom…
3. Sistemi life-critical
   Real-time, controlli militari, sistemi embedded…
4. Sistemi senza assistenza
   Sonde spaziali, satelliti…

Alcune cause di indisponibilità

(in ordine di complessità)

- Hardware
  - Mancanza di corrente
  - Guasto dei componenti
- Software
  - Bug
  - Upgrade/patch
- Sovraccarico
- Errore Umano
- Calamità Naturale
- Attacco Hacker/Terroristico

Catene funzionali e SPOF

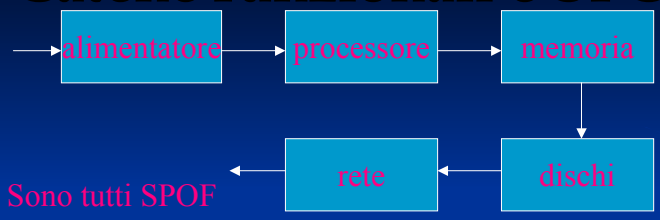

- SPOF: Single Point of Failure

  Componente critico in una catena funzionale.

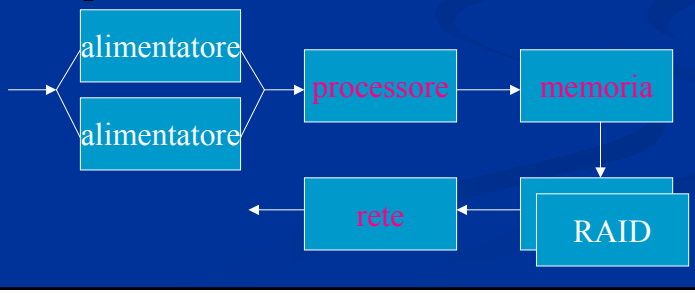

MTBF: Mean Time Between Failure

- Tempo medio tra due interruzioni consecutive
  - Hardware MTBF: della sola componente hardware
  - System MTBF: di tutto il sistema nel suo complesso (quello che conta per il servizio)
- Ridondanza hardware fa aumentare il system MTBF ma diminuire l'hardware MTBF (e quindi maggiore manutenzione)

Soluzione 1: Server Singolo (Processori tightly coupled)

- Semplice (inizialmente)
- Non molto scalabile
  - SMP: limitato a poche vie (processori)
  - NUMA: molto costoso
- SPOF
  - Hardware diventa cruciale
  - Singoli componenti possono essere ridondanti e hot pluggable ma il costo aumenta

Soluzione 2: Cluster (Processori loosely coupled)

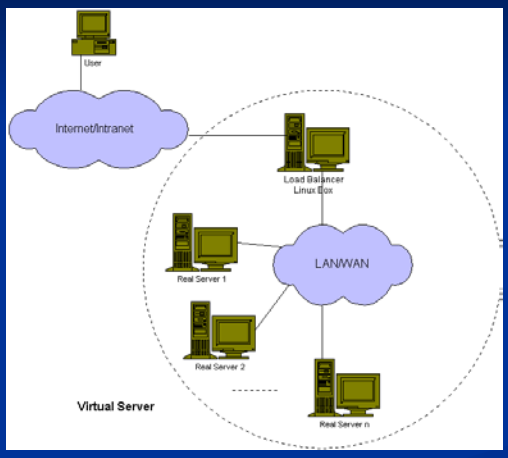

- Trasparente all'utente
  - Il cluster appare come una sola macchina
  - Applicabile a WAN
- Scalabile
  - Si aggiungono nuove macchine alla bisogna
- Fault-tolerant
  - Riconfigurazione automatica nel caso di fallimento di un nodo
- Economico
  - HW non specializzato

Linux Virtual Server + Linux-HA

Soluzione per cluster scalabili ad alta disponibilità risultante dall'unione di più iniziative Open Source.

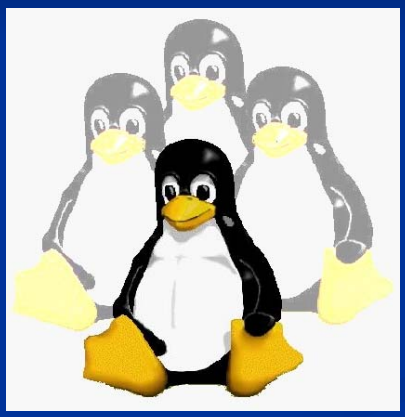

- Bilanciamento del carico
- Failure detection e recovery
- Riconfigurazione automatica
- Prezzo imbattibile!

Architettura generale LVS-HA

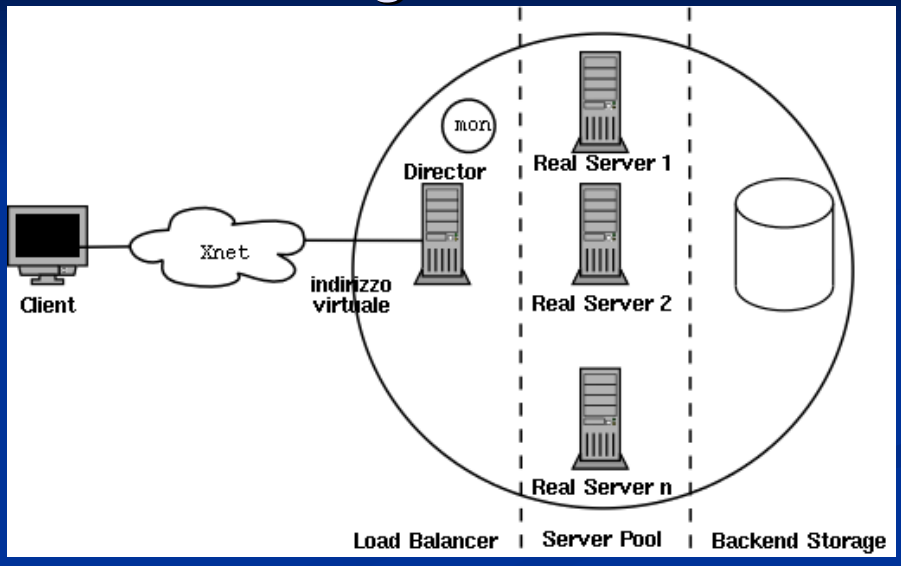

Front end: Load Balancer (Director)

- È l'unica macchina visibile dall'esterno
- Riceve le richieste dai client e le reinvia ai veri server (switch di livello 4), e viceversa
  - (in alcune configurazioni)
- Tutto questo avviene direttamente in kernel
  - IPVS: patch per il kernel
  - sfrutta SMP
  - basso overhead
  - un singolo director può gestire decine di real server

Pool dei Real server

- Implementano il servizio (WWW, Mail, SMB, DNS, …)
- Possono avere caratteristiche (anche S.O.) diverse
- Scalabile
  - nuovi nodi possono essere aggiunti run-time
  - il director può essere riconfigurato run-time
- Fault-tolerant per ridondanza
  - Lo stato dei real server viene monitorato dal director
  - In caso di rottura di un server, il director si riconfigura automaticamente escludendo il nodo

Monitoraggio risorse
-MON-

- `mon` è un sistema generale di monitoraggio di risorse (indipendente da LVS), scritto in Perl
- Architettura client/server a plugin
  - monitors: programmi client che verificano una data condizione/servizio (qualsiasi cosa).
  - `mon` è il server che riceve le notifiche dai monitors
  - alerts (upalerts): script eseguiti da `mon` in seguito ad un failure/ritorno in funzione
  - Monitors, alerts e upalerts possono essere aggiunti e modificati in qualsiasi momento

mon e LVS

- `mon` (client, server, alerts) viene eseguito sul director
- I monitor verificano il corretto funzionamento dei real server
- Gli alert riconfigurano il balancer togliendo il nodo fuori servizio (e spedendo un SMS al sistemista) e reintegrandolo non appena viene riparato
- I client non si accorgono di niente (o quasi…)

Il Director è un SPOF

- Soluzione: una copia del director, pronta a subentrare al principale in caso di failure

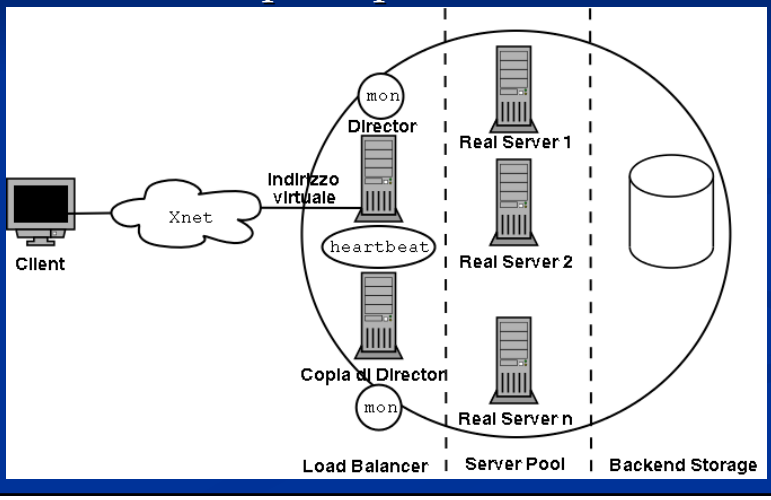

Heartbeat

Software (indipendente da LVS) che permette il subentro (*takeover*) della copia in caso di failure del master

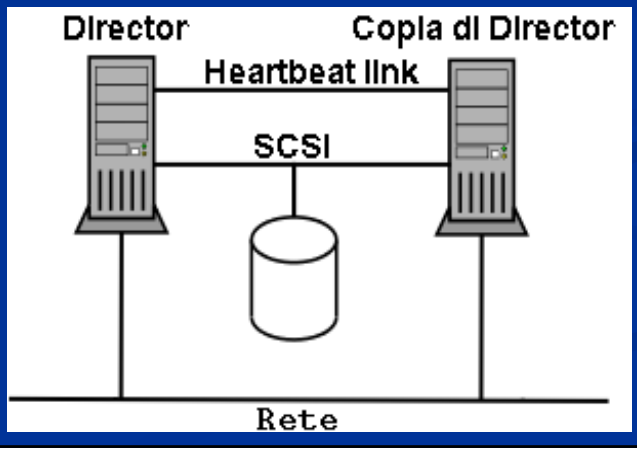

Heartbeat

- Implementa un heartbeat tra due (o più) nodi via seriale o UDP (possibilmente su crossover)
- Tipici valori: heartbeat=2s; deadtime=10s
- Quando il master viene riconosciuto morto:
  - Takeover delle risorse da parte del replica
    - indirizzi IP (via ARP gratuito)
    - mounting di device condivisi
    - lancio di servizi
  - Eventualmente supporta anche STONITH (shoot the other node in the head)
- Quando il master ritorna in vita (ritorno di battito), il replica rilascia le risorse

Backend storage

La logica di memorizzazione, eventualmente condivisa tra i server.

Un campo sterminato! Di interesse:

- File System journalled
  - EXT3, ReiserFS, JFS, XFS, GFS…
- File System distribuiti fault-tolerant
  - Coda, GFS, Intermezzo
- DBMS e/o applicativi legacy

CODA

Coda è un filesystem distribuito derivato da AFS2, e realizzato alla Carnegie Mellon University.

Tra le molte caratteristiche:

- Operatività offline per computazione mobile
- Alta performance attraverso client side persistent caching
- Replicazione dei Server
- Operatività anche durante parziale guasto della rete dei server
- Scalabile
- Open Source

Politiche di Scheduling

- Round Robin
- Weighted Round Robin
  - Si assegna un peso (potenza) ad ogni real server
- Least-Connection
  - Si seleziona il real server con il minor numero di connessioni attive (non adatto in ambienti eterogenei)
- Weighted Least-Connection
  - Si assegna un peso ad ogni real server; si seleziona quello con il minore rapporto #connessioni/peso
- Persistent Client Connection
  - Connessioni persistenti (ftp, https) dallo stesso client vengono reindirizzate sempre allo stesso real server

Politiche di scheduling (per cache cluster)

- Locality-Based least-connection
  - In base all'IP di destinazione, si tende a selezionare lo stesso server (se non sovraccarico)
- Locality-Based least-connection con replicazione
  - Come sopra, con sottocluster dinamici per IP destination
- Source/Destination IP Hashing
  - Tabella hash statica sugli indirizzi IP di source/destination

Tecniche di bilanciamento IP

- LVS/NAT: Network Address Translation
  - Il director instrada sia le richieste sia le risposte dei real server (rete cieca)
- LVS/TUN: Tunnelling su IP
  - Il director instrada solo le richieste con incapsulamento IPinIP; risposte dirette al client
- LVS/DR: Direct Routing
  - Il director instrada solo le richieste con riscrittura MAC su LAN; risposte dirette al client

LVS/NAT

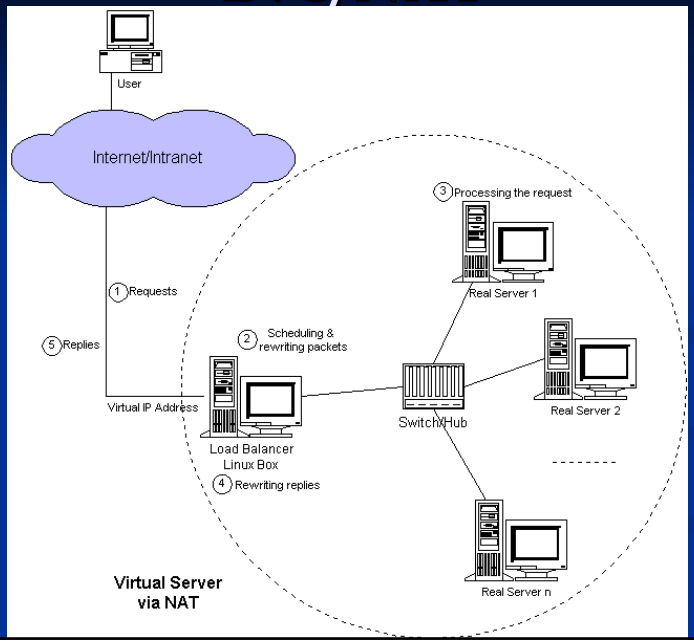

LVS/NAT

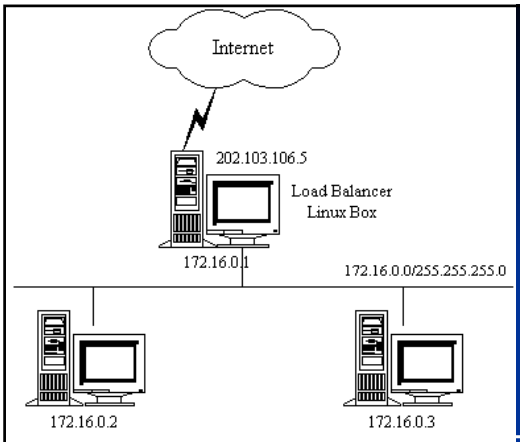

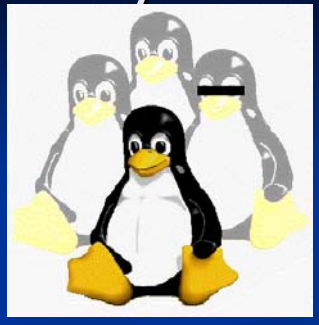

	Source	Destinazione
Richiesta dal client	202.100.1.2:3456	202.103.106.5:80
Richiesta al realserver	202.100.1.2:3456	172.16.0.3:8000
Risposta real server	172.16.0.3:8000	202.100.1.2:3456
Risposta al client	202.103.106.5:80	202.100.1.2:3456

LVS/NAT

- Qualsiasi real server può essere usato, senza modifiche
- I server possono risiedere su rete privata
- Sufficiente 1 indirizzo IP per tutto il cluster

- Director diventa collo di bottiglia: deve gestire tutto il traffico
- Poco scalabile

LVS/IP Tunnelling

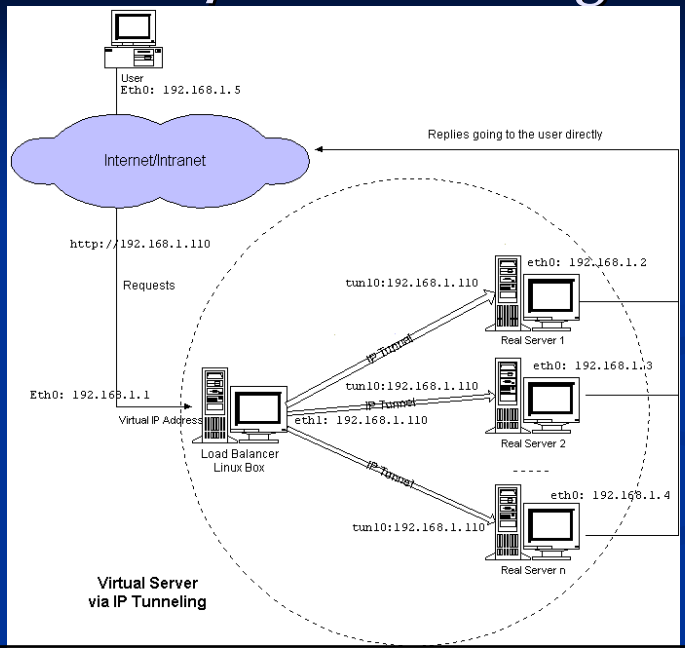

LVS/IP Tunnelling

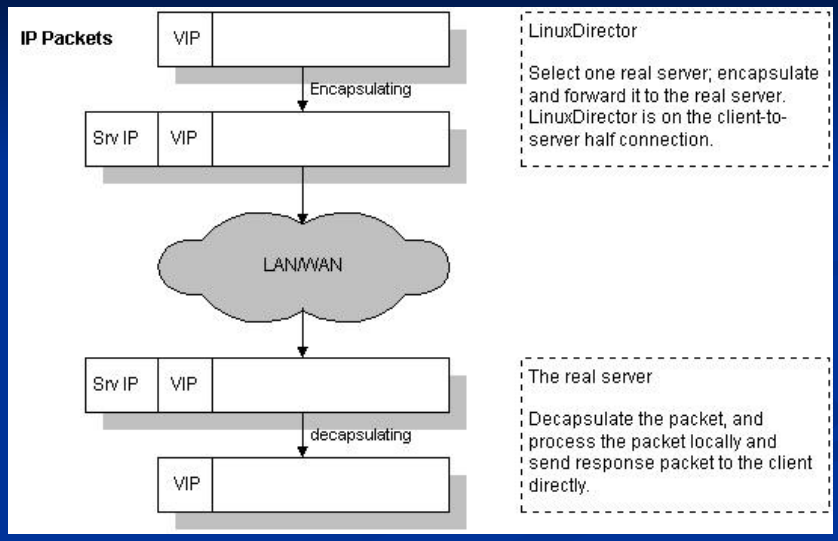

LVS/IP Tunnelling

- Il director deve gestire solo le richieste
- Le risposte non passano per il director
- Maggiore scalabilità
- I real server possono essere anche su reti diverse, o remote (cluster *geografici*)

- OS dei server deve supportare IP tunnelling
- I server devono avere indirizzo IP pubblico
- Overhead di incapsulazione

LVS/Direct Routing

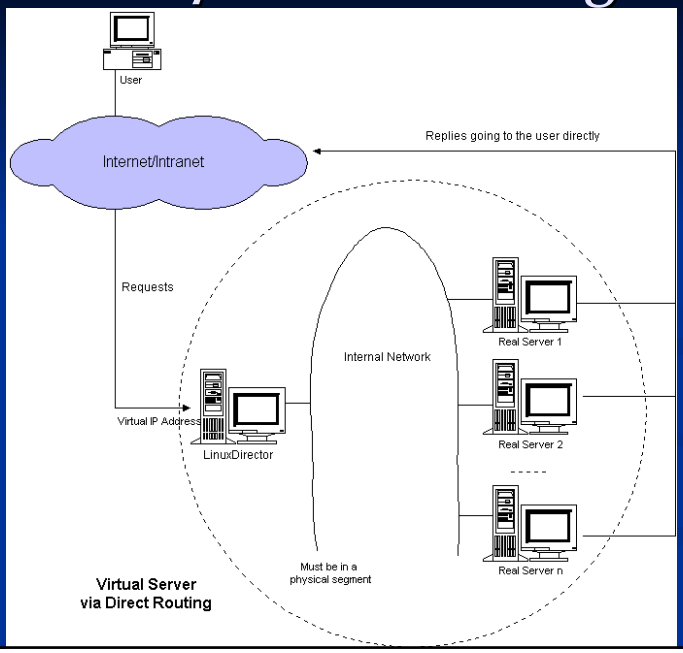

LVS/Direct Routing

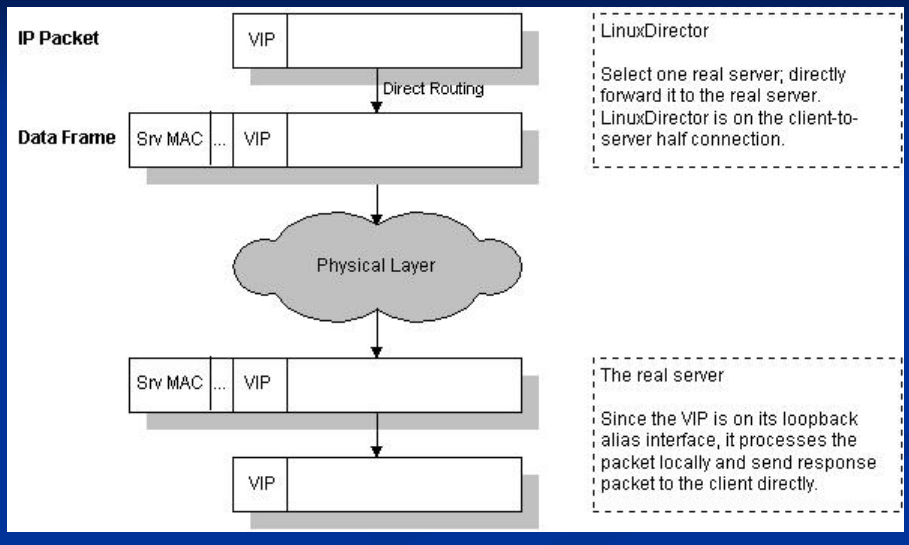

LVS/Direct Routing

- Il director deve gestire solo le richieste
- Le risposte non passano per il director
- Alta scalabilità
- Non c'è overhead di IP tunnelling

- Director e real servers devono stare sulla stessa rete fisica (hub/switch livello 2)
- I server devono avere indirizzo IP pubblico
- OS dei server deve implementare tunnels (interfacce non-ARPing)

Alcune installazioni di Linux Virtual Server

Linux.com	Portale Linux	LVS web cluster
Sourceforge.net	Sviluppo	LVS (ftp, http, https, ssh , cvs)
Themes.org	Repositorio temi	LVS web cluster
wwwcache.ja.net	Servizio proxy JANET (UK)	40 server in 3 cluster LVS
datingfacing.com	Incontri	LVS (~2Mhit/d)
www.zope.org	Web app. server	LVS web cluster
www.real.com	Multimedia	LVS (>20 nodi)
www.tiscali.it	Provider	LVS web cluster

Altre soluzioni su Linux

- RedHat Piranha: simile a LVS/NAT
  - IPVS kernel patch
  - nanny per monitorare i real server
  - pulse per gestire il replica del director
  - Piranha : GUI di amministrazione
- Heartbeat+ Linux Director Daemon
  - ldirectord è già installato con Heartbeat
  - Studiato appositamente per monitoraggio LVS
  - Più facile ma meno generale di mon

Conclusioni

- LVS-HA permette di costruire facilmente cluster ad alta disponibilità
- Permette il bilanciamento di qualsiasi servizio su TCP o UDP
- Scalabilità e fault-tolerance
- I real server non devono essere modificati
- Non supporta scheduling content-based
  (I servizi da bilanciare devono essere omogenei)
- Open source: modificabile secondo necessità
- Prezzo imbattibile!

Perché pagare il doppio?

Riferimenti

- www.linuxvirtualserver.org
- www.linux-ha.org
- www.coda.cs.cmu.edu
- www.kernel.org/software/mon/
- www.redhat.com/support/wpapers/piranha/