Openmosix e Beowulf: introduzione e confronto

Giovanni Perbellini

Agenda

- Cluster
  - Introduzione
  - Cluster ESD
- Openmosix
  - Comandi principali
- Beowulf (PVM)
  - Comandi principali
- Libreria PVM
  - API

Introduzione - Cluster

- *"In informatica, un **cluster** è un insieme di computer connessi tramite una rete telematica"* (Wikipedia)
- Lo scopo di un cluster è quello di distribuire una computazione molto complessa tra i vari computer che compongono il *cluster*
- In sostanza un problema che richiede molte elaborazioni per essere risolto viene scomposto in sottoproblemi separati i quali vengono risolti in parallelo

Requisiti cluster

- Sistema operativo
  - e.g., Linux con OpenMosix
- Hardware di rete
- Un algoritmo il cui calcolo può essere eseguito in parallelo

Tipi di cluster

- Failover
  - Monitoraggio dei servizi e migrazione in caso di caduta dei servizi
- Load-balancing
  - Bilanciamento dei processi con migrazione in caso di saturazione delle risorse
  - Esempio: Openmosix
- High Performance Computing (HPC)
  - I processi vengono sparsi sui nodi del *cluster*
  - Esempio: Beowulf

Cluster ESD

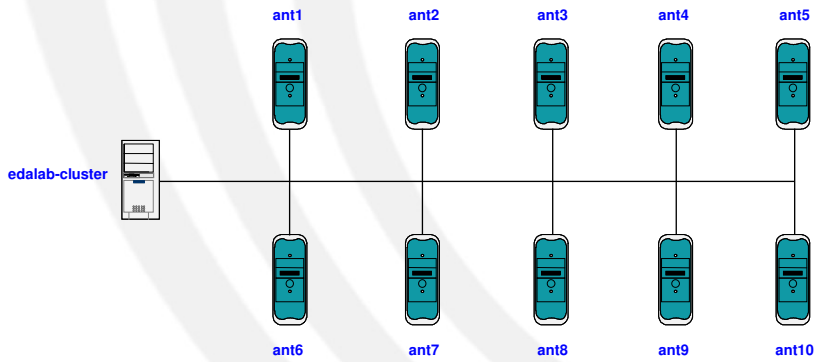

Openmosix - Introduzione

- Modifiche al kernel Linux per abilitare la migrazione dei processi
- Web Link: http://openmosix.sourceforge.net
- 2 componenti principali:
  - Patch per il Kernel del O.S.
    - Licenza GPL
  - User-space tools
    - Licenza GPL
    - Funzioni per la comunicazione tra i nodi e interfaccia per le funzioni kernel

Openmosix - Obiettivo

- Migrazione automatica dei ***processi*** tra i nodi del cluster in modo da bilanciare il carico
- I nodi del cluster notificano agli altri nodi circa il loro stato
  - Esempio: numero di processi eseguiti, uso del processore e della memoria
- Se un nodo del cluster determina che un altro nodo ha più risorse per gestire un processo, il processo viene migrato su un altro nodo
- Controllo centralizzato di tipo master/slave

Openmosix – Vantaggi (I)

- Adattabile: Non è necessario utilizzare nodi identici, ma possono essere usate varie tipologie di CPU
- Economico: Non è necessario usare HW dedicato
- Scalabile: per aumentare le prestazioni è sufficiente aumentare il numero dei nodi (max 65536)

Openmosix – Vantaggi (II)

- Trasparente: Una volta in esecuzione, sarà il sistema stesso a bilanciare il carico di lavoro e a ripartire i processi sui vari nodi.
  Nessun cambiamento al codice da parallelizzare (nessuna libreria richiesta).
- Flessibile: E' possibile aggiungere o togliere un nodo senza dover bloccare tutto il *cluster*

Openmosix - Svantaggi

- Esecuzione lenta per i processi che fanno molti I/O runs
  - Tutti gli I/O hanno bisogno di essere comunicati tra i nodi sorgente e destinazione del cluster
- Dispendiosa l'esecuzione di processi paralleli (e.g., applicazioni scientifiche) che hanno bisogno di accedere a grossi file di dati
  - Soluzione: MOPI (MOSIX Parallel I/O)
  - Divisione del file di dati tra i nodi del cluster e quando un processo ha bisogno di accedere a certe porzioni del file viene migrato sull'appropriato nodo

Openmosix – Esempi OK

- Programmi che eseguono "fork" per creare processi figli
- Programmi che creano più istanze dello stesso programma
- Esempi:
  - MatLab 5
  - MJPEG tools (gestione di file audio/video)

Openmosix – Esempi NO

- Programmi che fanno uso di memoria condivisa
- Esempi:
  - Oracle
  - Postgres
- Esistono alcune *patch* per eliminare il problema

Openmosix – user-space tools

- **`mosmon`** (openMosix monitor)
  - permette di vedere lo stato di tutti i nodi incluso l'utilizzo della cpu , la memoria installata, memoria usata, etc.
- **`mtop`**
  - versione potenziata di top che mostra su quale nodo viene eseguito un processo

Openmosix – user-space tools

- **`mps`**
  - versione potenziata di `ps`
  - mostra anche il numero dei nodi
- **`mosctl whois`**
  - **`mosctl whois "nodenumber"`** è possibile vedere l'ip o l'hostname di ***`nodenumber`***

Beowulf

- Insieme di SW e librerie per emulare un'architettura concorrente
- Obiettivo: permettere all'insieme di macchine di cooperare per eseguire un calcolo parallelo
- Modalità: Permette al programmatore di dividere i compiti da svolgere su un gruppo di computer collegati in rete e di riunire i risultati dei singoli processi per ottenere la soluzione del problema trattato

Beowulf

- Le più famose
  - PVM (Parallel Virtual Machine)
  - MPI (Message Passing Interface)

PVM – Principi base

- Applicazione è suddivisa in task, responsabile di una parte di computazione dell'intera applicazione
- Task (processo)
  - Unità di lavoro che viene eseguita in parallelo in PVM
  - *Processo* sequenziale e indipendente che alterna tra computazione e comunicazione
- I task dell'applicazione eseguono su un insieme di macchine che sono selezionate dall'utente
  - Nodi selezionati per una determinata esecuzione
  - Aggiunta/rimozione nodi a run-time

PVM – Principi base

- Modello message-passing
  - Invio e ricezione di messaggi tra la collezione di task
- Supporto dell'eterogenietà
  - PVM supporta eterogeneità in termini di nodi (macchine), rete e applicazioni

PVM - Componenti

- Composto da due parti
  - Demone pvmd3
    - Risiede sul nodo che fa da macchina virtuale
  - Libreria di routine PVM
    - Insieme di primitive utili per la cooperazione tra i task di un'applicazione
    - Mesage passing, spawning processi, coordinazione dei task, etc.

PVM - Parallelismo

- *Functional parallelism*
  - L'applicazione è suddivisa in funzioni che vengono attribuite a diversi task
    - Esempio: input, output, setup, solution, display
- *Data parallelism*
  - I task sono tutti uguali ma ognuno risolve solo una parte dei dati
  - SPMD (Single Program Multiple Data)
- PVM può supportare entrambi i metodi nella stessa esecuzione

PVM – task

- Ogni task è identificato da un TID (*Task Identification*)
  - Unico su tutto il cluster
- Forniti dal demone **`pvmd`**
  - Non possono essere scelti dall'utente
- PVM contiene diverse funzioni che ritornano il TID per identificare i task

PVM – Funzioni di libreria (I)

- **`pvm_spawn()`** per generare dei task (che verranno "allocati" automaticamente sulle macchine del *cluster*).
- **`pvm_pack()`** è una famiglia di funzioni, una per ogni tipo di dato; converte i dati in un formato standard (per permettere lo scambio dei dati tra architetture eterogenee) e li copia nel buffer di invio.
- **`pvm_unpack()`** è la simmetrica della **`pvm_pack`**, per la riconversione dei dati dopo la ricezione.
- **`pvm_send()`** invia dei dati ad un task.
- **`pvm_mcast()`** invia dei dati a più task (multicast).
- **`pvm_recv()`** riceve dei dati da un task specifico (o da qualunque task).

PVM – Funzioni di libreria (II)

- **`pvm_trecv()`** riceve dei dati, entro un certo tempo max, altrimenti ritorna.
- **`pvm_nrecv()`** riceve dei dati se sono già presenti, altrimenti esce (*receive* non bloccante).
- **`pvm_joingroup()`** aggiunge il task chiamante al gruppo specificato (se non esiste, lo crea).
- **`pvm_lvgroup()`** lascia un gruppo.
- **`pvm_bcast()`** manda un messaggio a tutti i task del gruppo.
- **`pvm_barrier()`** ferma l'esecuzione del task, finchè tutti i membri del gruppo chiamano **`pvm_barrier`**() (per la sincronizzazione).

PVM

- Linguaggi: C, C++, Fortran
- Web link
  - http://www.netlib.org/pvm3/index.html
  - ftp://ftp.netlib.org/pvm3
- Librerie C/C++: **`libpvm3.a`** e **`libgpvm3.a`**
- Demone
  - % pvm
    - Per accedere al prompt dei comandi di PVM
  - % xpvm
    - PVM con interfaccia grafica

PVM – Comandi (I)

- **`pvm> add hostname`**
  - Aggiunta di **hostname** alla macchina virtuale
- **`pvm> delete hostname`**
  - Rimozione di **`hostname`** dalla macchina virtuale
  - I processi in esecuzione su **`hostname`** vengono persi
- **`pvm > conf`**
  - Configurazione della macchina virtuale (*hostname* presenti sulla macchina virtuale, task ID, tipo di architetture, etc.)

PVM – Comandi (II)

- **`pvm> ps -a`**
  - Elenco di tutti i processi in esecuzione sulla macchina virtuale, i loro task ID, etc.
- **`pvm> quit`**
  - Uscita dal prompt dei comandi, lasciando in esecuzione i demoni e tutti i processi PVM in esecuzione
- **`pvm> halt`**
  - Uscita dal prompt dei comandi, con terminazione di tutti i processi PVM e di tutti i demoni

PVM – Comandi (III)

- **`pvm> spawn`**
  - Inizia l'esecuzione di un'applicazione
  - Opzioni:
    - **`count`**
      - Numero di task (default = 1)
    - **`host`**
      - Esecuzione su un determinato host (default = any)
    - **`?`**
      - Abilita il debug
    - **`> file`**
      - Redirezione dell'output del task su file