

ENEA GRID

Seminario avanzato per l'utente di cresco

Autore: Alessandro Secco
alessandro.secco@nice-italy.com

Seminario avanzato per l'utente di Cresco

- Riepilogo utilizzo di base di LSF
- LSF: job paralleli avanzati
- LSF: i flussi di job
- LSF: gruppi di job
- Riferimenti

Riepilogo utilizzo di base di LSF

Riepilogo utilizzo di base di LSF

- Nei seminari precedenti sono state visitate tutte le principali opzioni di lancio di un job tramite LSF:
 - Lancio di un job seriale
 - Lancio di un job seriale multi-case
 - Code seriali:
 - `cresco_serh48` e `cresco_serh72`
 - Lancio di un job parallelo openmpi
 - Lancio di un job parallelo mvapich
 - Code parallele:
 - `cresco_512h2`, `cresco_512h8`, `cresco_512h24` (> 512 processori)
 - `cresco_128h2`, `cresco_128h8`, `cresco_128h24` (> 128 e <= 512 processori)
 - `cresco_16h2`, `cresco_16h8`, `cresco_16h24` (> 16 e <= 128 processori)
 - `cresco_h2`, `cresco_h8`, `cresco_h24` (> 8 e <= 16 processori)

Riepilogo utilizzo di base di LSF

- I seminari hanno dimostrato la compilazione tramite **mpicc** di un semplice job mpi ed il lancio tramite LSF

```
/* hello.c
 *
 * Simple "Hello World" program in MPI.
 * NOTA: Programma di test preso in prestito dal sito del CERN
 */
#include "mpi.h"
#include <stdio.h>
int main(int argc, char *argv[]) {
    int numprocs; /* Number of processors */
    int procnum; /* Processor number */
    /* Initialize MPI */
    MPI_Init(&argc, &argv);
    /* Find this processor number */
    MPI_Comm_rank(MPI_COMM_WORLD, &procnum);
    /* Find the number of processors */
    MPI_Comm_size(MPI_COMM_WORLD, &numprocs);
    printf ("Hello world! from processor %d out of %d\n", procnum, numprocs);
    /* Shut down MPI */
    MPI_Finalize();
    return 0;
}
```

Riepilogo utilizzo di base di LSF

- Script generico di lancio per job basati su **openmpi**:

```
#!/bin/sh
```

```
PROCS=`cat $LSB_DJOB_HOSTFILE | wc -l`
```

```
mpirun -n $PROCS --mca pls_rsh_agent "blaunch.sh" -hostfile $LSB_DJOB_HOSTFILE ./a.out
```

- Script generico di lancio per job basati su **mvapich**:

```
#!/bin/sh
```

```
PROCS=`cat $LSB_DJOB_HOSTFILE | wc -l`
```

```
mpirun_rsh -rsh -np $PROCS -hostfile $LSB_DJOB_HOSTFILE ./a.out
```

- Sottomissione del job:

```
bsub -q cresco_128h2 -n 200 -o test.%J ./lancio.sh
```

LSF: job paralleli avanzati

Regole generali

- Nei primi mesi di cresco, LSF è stato integrato con molti codici
- Nello script di lancio, le regole sono:
 - Sostituire “ssh” con “blaunch.sh”:
 - Con mvapich basta usare `mpirun_rsh -rsh`
 - Con openmpi bisogna mettere in testa a `$PATH` `/afs/enea.it/software/bin/support/ssh`, o usare l'opzione di `mpirun -mca pls_rsh_agent “blaunch.sh”` (se possibile)
 - Contare i processori passati da LSF
 - `PROCS=`cat $LSB_DJOB_HOSTFILE | wc -l``
 - Usare `$LSB_DJOB_HOSTFILE` come parametro da passare a “hostfile” o “machinefile”.

Caso 1: processi eterogenei

- Il caso è stato proposto da un utente che aveva la necessità di lanciare 3 processi diversi all'interno dello stesso job mpi.
- I 3 processi avevano finalità diverse, ma comunicavano tra loro in mpi:
 - I processi andavano lanciati tutti all'interno dello stesso job di LSF
 - Si doveva trovare un modo per distribuire i processi sui nodi
- La soluzione proposta (attualmente in fase di sperimentazione) è basata su uno script.

Caso 1: processi eterogenei (openmpi)

```
#!/bin/sh
```

```
PROC1=1
NAME1=./a.out
PROC2=40
NAME2=./b.out
PROC3=15
NAME3=./c.out
PROCS=56
```

```
PATH=/afs/enea.it/software/bin/support/ssh:$PATH
```

```
cat $LSB_DJOB_HOSTFILE | head -$PROC1 > h1
cat $LSB_DJOB_HOSTFILE | head -`expr $PROC2 + $PROC1` | tail -$PROC2 > h2
cat $LSB_DJOB_HOSTFILE | tail -$PROC3 > h3
```

```
rm -f launchfile
for i in `cat ./h1`
do
    echo "-np 1 --host $i $NAME1" >> launchfile
done
for i in `cat ./h2`
do
    echo "-np 1 --host $i $NAME2" >> launchfile
done
for i in `cat ./h3`
do
    echo "-np 1 --host $i $NAME3" >> launchfile
done
```

```
mpirun -app ./launchfile
```

Assegnazione
processi e processori

PATH per blaunch.sh

Divisione dei
processori

Creazione di una
riga nel file di lancio
per ogni processo

Lancio del job

Caso 2: fluent

- Fluent è un codice commerciale di fluido dinamica
- La sua integrazione con il mondo cresco è stata semplice: è bastato seguire la mini-guida.

```
#!/bin/sh
```

```
PATH=/afs/enea.it/software/bin/support/ssh:$PATH  
export PATH
```

```
PROCS=`cat $LSB_DJOB_HOSTFILE | wc -l`  
fluent63 -t$PROCS -cnf=$LSB_DJOB_HOSTFILE $*
```

Altri casi

- Altri codici sono stati integrati:
 - OpenFOAM
 - CPMD
 - MCNPX
 - ...
- In linea di massima non cambia nulla rispetto a quanto detto nelle regole generali, ma è necessario contattare gli amministratori per avere dettagli
- Si vedano i riferimenti per integrare nuovi codici o utilizzare integrazioni già fatte.

LSF: I flussi di job

LSF: i flussi di job

- Forse pochi utenti sanno che Lsf può gestire i flussi di job.
- I flussi sono utili in molti ambiti:
 - Job dipendente dal file di output di un altro
 - Job che collezioni l'output di diversi job precedenti
 - Sequenze di job automatizzate (loop)
- Per pianificare un flusso di job, è necessario conoscere un po' di scripting, alcune nozioni di LSF ed un minimo di progettazione di algoritmi.


Un utile trucco

- In molti casi servirà avere esattamente il jobid come output di bsub:
 - `bsub ... | awk -F'<' '{print $2}' | awk -F'>' '{print $1}'`
- Si potrebbe mettere il filtro in uno script dentro la propria home directory (jobid.sh):

```
#!/bin/sh
```

```
awk -F'<' '{print $2}' | awk -F'>' '{print $1}'
```

Esercizio: lancio di 3 job ed attesa



Esercizio: lancio di 3 job ed attesa

sub.sh:

```
#!/bin/sh
```

```
JOBID1=`bsub sleep 10 | ./jobid.sh`
```

```
JOBID2=`bsub sleep 10 | ./jobid.sh`
```

```
JOBID3=`bsub sleep 10 | ./jobid.sh`
```

```
export JOBID1 JOBID2 JOBID3
```

```
DEPEND1=`echo "done($JOBID1) && done($JOBID2) && done($JOBID3)"`
```

```
JOBID4=`bsub -w "$DEPEND1" -o done ./done.sh | ./jobid.sh`
```

```
export JOBID4
```

```
DEPEND2=`echo "exit($JOBID1) || exit($JOBID2) || exit($JOBID3) ||
```

```
ended($JOBID4)"`
```

```
JOBID5=`bsub -w "$DEPEND2" -o clean ./clean.sh`
```

done.sh:

```
#!/bin/sh
```

```
echo "$JOBID1, $JOBID2, $JOBID3 done"
```

clean.sh:

```
bkill $JOBID1 $JOBID2 $JOBID3 $JOBID4 >/dev/null 2>&1
```

```
echo "game over"
```

Esercizio: utilizzo in pratica

- L'esercizio potrebbe essere utile quando
 - è necessario aspettare la fine di una serie di job per collezionare gli output tramite uno script
 - se i job non vanno a buon fine, lanciare uno script di pulizia
- Questo esempio, unito alla funzionalità di job array, o lancio di job paralleli, permette di creare veri e propri algoritmi di lancio dei job
 - Un job in attesa potrebbe, al suo interno, lanciare un nuovo bsub, creando una condizione simile ad un ciclo “while”
- **ATTENZIONE:** la durata del flusso non può andare oltre la durata del token di AFS.

Gruppi di job

Gruppi di job

- In alcune circostanze, può essere importante raggruppare i propri job personali
 - Finalità di controllo.
- In altri casi, potrebbe essere interessante gestire i job del proprio gruppo di lavoro:
 - Gestione centralizzata di gruppi di utenti
 - Gestione gerarchica dei gruppi
- L'uso dei gruppi è utile se si vuole richiedere all'amministratore un "Service Level Agreement", un accordo per ottenere un certo livello di servizio.

Aggiunta di un gruppo

- Un gruppo può essere creato in 2 modi:
 - `bsub -g /nome <nomejob>` (se “/nome” è inesistente)
 - `bgadd /nome`
- L'utente che aggiunge il gruppo ne diventa automaticamente l'amministratore
- Il gruppo viene cancellato in automatico alla fine dei job nel primo caso. Altrimenti:
 - `bgdel /nome`
- L'opzione -L di `bgadd` permette di definire un massimo numero di job contemporaneamente in stato “run” per gruppo.

Uso del gruppo e gestione

- Per usare il gruppo si lancia:
 - `bsub -g /nome <nomejob>`
 - La variabile d'ambiente `LSB_DEFAULT_JOBGROUP` lancia su un gruppo in automatico
- L'utente amministratore del gruppo, avrà possibilità di gestire tutti i job di tutti gli utenti del proprio gruppo:
 - `bkill`, `bstop`, `bresume`, `bmod`, `bswitch`
- Questo è utile per non dover chiamare l'amministratore se un utente lancia un gran numero di job e si deve fermarli quando esso non è presente.

Gerarchia tra gruppi

- All'interno dello stesso gruppo, è possibile definire sottogruppi.
 - `bgadd /nome/sottonome`
 - L'amministratore di `/nome` sarà l'amministratore anche di `/nome/sottonome`
 - Il creatore di `/nome/sottonome` non è necessariamente il creatore di `/nome`, e potrà amministrare solo i job del suo sottogruppo.
- Per vedere tutti i gruppi definiti e sapere chi li amministra esiste il comando `bjgroup` che dà l'elenco di tutti i gruppi e tutti gli amministratori.

Considerazioni sui gruppi

- I gruppi sono gestiti in modo autonomo dagli utenti.
- Ogni utente può decidere di creare gruppi o sottogruppi in modo indipendente dagli amministratori
 - Questo è importante nel caso, per esempio, in cui un utente voglia poter agire da “amministratore locale” all'interno dei job dei propri collaboratori.
 - Una volta organizzato il proprio gruppo, l'utente può contrattare dei servizi speciali con l'amministratore.
- I gruppi non hanno finalità di accounting.
L'accounting di gruppo può essere collezionato dall'opzione -J (progetto) di bsub o tramite l'uso di Service Level Agreement.

Applicazione pratica

- Enea è divisa in macro-gruppi (fus, erg, fis, ...)
- All'interno dei gruppi si possono definire dei sottogruppi, ognuno dei quali ha sue finalità e può avere un suo amministratore
- L'amministratore di gruppo può chiedere alla gestione di crescere delle condizioni particolari per soddisfare i propri requisiti di servizio (SLA):
 - Deadline
 - Velocità (maggior numero di job contemporanei)
 - Throughput (maggior numero di job finiti)

Riferimenti

Riferimenti

- <http://gridticket.enea.it>: permette di aprire “ticket” di supporto. E' il modo consigliato per segnalare problemi inerenti ENEA grid.
- griduser@enea.it: è possibile contattare tutti gli utenti per raccogliere esperienze sull'uso della GRID.
- alessandro.secco@nice-italy.com: problemi relativi a questo corso possono essere indirizzati a me. La collaborazioni di tutti è gradita.