Les clusters de calcul

Configuration et outils pour la recette Tuteur : M. Lucas NUSSBAUM

S. Badia, G. Delourmel, L. Didry & J. Vaubourg

IUT Nancy Charlemagne, Université Nancy 2

31 mars 2010



Introduction	
Inventaire	
Les technologies liées aux <i>clusters</i>	
Les tests de débits/latences	
Un environnement rapide	
Problèmes généraux	
Conclusion	

Historique du calcul haute performance Organisation du projet Grid5000 Utilisation Objectifs du projet

Partie I


Introduction

- 1 Historique du calcul haute performance
- Organisation du projet Grid5000
- 3 Utilisation
- Objectifs du projet

XVIIème siècle : la première machine mécanique, la pascaline




XIXème siècle : la machine mécanique de BABBAGE



1945 : architecture de Von Neumann

1956 : premiers ordinateurs basés sur cette architecture et utilisant les possibilités des semi-conducteurs



1970 : la société *Cray* développe une architecture permettant un coût d'un million de dollars pour un million d'opérations par seconde



- Trente ans plus tard, le coût reste le même pour un nombre d'opérations multiplié par un million
- Aujourd'hui, le plus puissant supercalculateur possède un capacité de calcul de 1759 téraflops (10¹² opérations par seconde)
- L'avenir : certains pensent pouvoir atteindre l'exaflop (10¹⁸ opérations par seconde) d'ici 2015

- Trente ans plus tard, le coût reste le même pour un nombre d'opérations multiplié par un million
- Aujourd'hui, le plus puissant supercalculateur possède un capacité de calcul de 1759 téraflops (10¹² opérations par seconde)
- L'avenir : certains pensent pouvoir atteindre l'exaflop (10¹⁸ opérations par seconde) d'ici 2015

- Trente ans plus tard, le coût reste le même pour un nombre d'opérations multiplié par un million
- Aujourd'hui, le plus puissant supercalculateur possède un capacité de calcul de 1759 téraflops (10¹² opérations par seconde)
- L'avenir : certains pensent pouvoir atteindre l'exaflop (10¹⁸ opérations par seconde) d'ici 2015

- Historique du calcul haute performance
- 2 Organisation du projet Grid5000
- 3 Utilisation
- 4 Objectifs du projet

Le but du projet Grid5000 est d'obtenir une grille de calcul de 5000 processeurs répartis sur la France entière en 9 sites reliés via RENATER



- Chaque site possède un ou plusieurs clusters
- Chaque site est géré par son (ses) propre(s) administrateur(s)
- Cela peut conduire à un comportement différent selon le site :
 - les logiciels ou bibliothèques installés ne sont pas forcément les mêmes
 - certains permettent un accès depuis l'extérieur, comme Lyon, mais pas d'autres, comme Nancy

- Chaque site possède un ou plusieurs clusters
- Chaque site est géré par son (ses) propre(s) administrateur(s)
- Cela peut conduire à un comportement différent selon le site :
 - les logiciels ou bibliothèques installés ne sont pas forcément les mêmes
 - certains permettent un accès depuis l'extérieur, comme Lyon, mais pas d'autres, comme Nancy

- Chaque site possède un ou plusieurs clusters
- Chaque site est géré par son (ses) propre(s) administrateur(s)
- Cela peut conduire à un comportement différent selon le site :
 - les logiciels ou bibliothèques installés ne sont pas forcément les mêmes
 - certains permettent un accès depuis l'extérieur, comme Lyon, mais pas d'autres, comme Nancy

- Chaque site possède un ou plusieurs clusters
- Chaque site est géré par son (ses) propre(s) administrateur(s)
- Cela peut conduire à un comportement différent selon le site :
 - les logiciels ou bibliothèques installés ne sont pas forcément les mêmes
 - certains permettent un accès depuis l'extérieur, comme Lyon, mais pas d'autres, comme Nancy

- Chaque site possède un ou plusieurs clusters
- Chaque site est géré par son (ses) propre(s) administrateur(s)
- Cela peut conduire à un comportement différent selon le site :
 - les logiciels ou bibliothèques installés ne sont pas forcément les mêmes
 - certains permettent un accès depuis l'extérieur, comme Lyon, mais pas d'autres, comme Nancy

- Historique du calcul haute performance
- 2 Organisation du projet Grid5000
- Utilisation
- 4 Objectifs du projet

- On se connecte par SSH à un site le permettant
- Immédiatement, le répertoire /home de l'utilisateur est monté en NFS
- On réserve un certain nombre de nœuds pour un temps donné
- Cette réservation peut être précise quant au nombre de machines et à leurs caractéristiques et peut se faire à l'avance

- On se connecte par SSH à un site le permettant
- Immédiatement, le répertoire /home de l'utilisateur est monté en NFS
- On réserve un certain nombre de nœuds pour un temps donné
- Cette réservation peut être précise quant au nombre de machines et à leurs caractéristiques et peut se faire à l'avance

- On se connecte par SSH à un site le permettant
- Immédiatement, le répertoire /home de l'utilisateur est monté en NFS
- On réserve un certain nombre de nœuds pour un temps donné
- Cette réservation peut être précise quant au nombre de machines et à leurs caractéristiques et peut se faire à l'avance

- On se connecte par SSH à un site le permettant
- Immédiatement, le répertoire /home de l'utilisateur est monté en NFS
- On réserve un certain nombre de nœuds pour un temps donné
- Cette réservation peut être précise quant au nombre de machines et à leurs caractéristiques et peut se faire à l'avance

- Historique du calcul haute performance
- 2 Organisation du projet Grid5000
- 3 Utilisation
- Objectifs du projet

- la conformité des clusters à l'appel d'offre auquel il fait suite :
 - conformité matérielle
 - conformité des vitesses des disques durs
- les performances réseau
- la bonne interconnexion des nœuds

- la conformité des *clusters* à l'appel d'offre auquel il fait suite :
 - conformité matérielle
 - conformité des vitesses des disques durs
- les performances réseau
- la bonne interconnexion des nœuds

- la conformité des *clusters* à l'appel d'offre auquel il fait suite :
 - conformité matérielle
 - conformité des vitesses des disques durs
- les performances réseau
- la bonne interconnexion des nœuds

- la conformité des *clusters* à l'appel d'offre auquel il fait suite :
 - conformité matérielle
 - conformité des vitesses des disques durs
- les performances réseau
- la bonne interconnexion des nœuds

- la conformité des *clusters* à l'appel d'offre auquel il fait suite :
 - conformité matérielle
 - conformité des vitesses des disques durs
- les performances réseau
- la bonne interconnexion des nœuds

Problématique Ivcmp Ivbon Problèmes rencontrés

Partie II

Inventaire

- ⑤ Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



- Vérifier la conformité des nœuds à l'appel d'offre
- Vérifier l'homogénéité par cluster
- Vérifier la conformité à l'OAR Database
- Détecter des pannes ou des disfonctionnements éventuels

- Vérifier la conformité des nœuds à l'appel d'offre
- Vérifier l'homogénéité par cluster
- Vérifier la conformité à l'OAR Database
- Détecter des pannes ou des disfonctionnements éventuels

- Vérifier la conformité des nœuds à l'appel d'offre
- Vérifier l'homogénéité par cluster
- Vérifier la conformité à l'OAR Database
- Détecter des pannes ou des disfonctionnements éventuels

- Vérifier la conformité des nœuds à l'appel d'offre
- Vérifier l'homogénéité par cluster
- Vérifier la conformité à l'OAR Database
- Détecter des pannes ou des disfonctionnements éventuels

- ⑤ Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbor
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



- Langage Perl
- Différents outils *Unix*
- Différents modules Perl :

- Langage Perl
- Différents outils *Unix* :
- Différents modules Perl

- Langage Perl
- Différents outils Unix :

lshw

```
lspci
uname
ifconfig
cat /proc/cpuinfo
```

- Langage Perl
- Différents outils Unix :

```
lshw
lspci
```

```
uname
ifconfig
cat /proc/cpuinfo
```

- Langage Perl
- Différents outils Unix :

```
lshw
lspci
uname
ifconfig
cat /proc/cpuinfo
```

- Langage Perl
- Différents outils Unix :

```
lshw
lspci
uname
ifconfig
cat /proc/cpuinfe
```

- Langage Perl
- Différents outils Unix :

```
lshw
lspci
uname
ifconfig
cat /proc/cpuinfo
```

- Langage Perl
- Différents outils *Unix* :
- Différents modules *Perl* :

- Langage Perl
- Différents outils *Unix* :
- Différents modules Perl :

YAML

Data::Dumper

- Langage Perl
- Différents outils *Unix* :
- Différents modules Perl :

YAML

Data::Dumper

XML::Simple

- Langage Perl
- Différents outils *Unix* :
- Différents modules Perl :

YAML

Data::Dumper
XML::Simple

- Langage Perl
- Différents outils *Unix* :
- Différents modules *Perl* :


YAML

Data::Dumper
XML::Simple


- 5 Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbor
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés




• Récupération de la liste des nœuds



• Installation de 1shw en parallèle




• Récupération des informations en parallèle



 Récupération des informations de l'OAR Database et comparaison avec les nœuds



Comparaison des nœuds entre eux



Sortie au format YAML

```
--- Notice that the printed value are from Unix tools, not from OAR database ---
 cluster : griffon
 cpuarch: x86 64
 cpucore : 4
 cpufreg: 2.5
 cputype : Intel(R) Xeon(R) CPU L5420 @ 2,50GHz
 diskmodel : Hitachi HDP72503
 disksize : 320
 disktype : sata
 ib10a : ~
 iblOgmodel : ~
 ib20g : 1
 ib20gmodel: MT26418
 memnode : 16384
 myrilOg : ~
 mvrilOamodel : ~
 myri2q : ~
 myri2gmodel : ~
 nodes :
   griffon-90.nancy.grid5000.fr : ~
   griiton-92.nancy.grid5000.ir : ~
```

Affichage des incohérences au niveau de l'OAR Database

```
The Oar database couffreq information of the node grelon-53.nancy.grid5000.fr is not the same as we check on the node ...

OAR database: 2 Unix tools: 1.6

The Oar database ethnb information of the node grelon-53.nancy.grid5000.fr is not the same as we check on the node ...

OAR database: 2 Unix tools: 1

The Oar database cyfreq information of the node grelon-54.nancy.grid5000.fr is not the same as we check on the node ...

OAR database: 2 Unix tools: 1.6

The Oar database ethnb information of the node grelon-54.nancy.grid5000.fr is not the same as we check on the node ...

OAR database: 2 Unix tools: 1.6

OAR database: 2 Unix tools: 1.6
```

- 5 Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Options disponibles

Ivcmp - copyright (c) 2010 Guillaume Delourmel <delourmel quillaume@vahoo.fr>, Luc Didry <lucdidry@free.fr> Inventory script which compares the informations in the Oar database and informations returned by Unix tools such as lshw, lspci, etc. It can be used to see if all the nodes of a cluster have the same material You need a ssh key with an empty passphrase in order to avoid to type the passphrase for each node You need to be root on the nodes in order to get all the required informations with lshw Usage : ./ivcmp (OPTIONS)... -f. --file [FILE] specify the file containing the list of the nodes (\$OAR FILE NODES by default) This file need to have one node per line (duplicate nodes will be ignored) -o. --output [FILE] print the result in the file in YAML format -p, --parameter CRITERION [CRITERION]... check the nodes against specified criteria automatically install lshw on nodes (lshw is required) automatically remove the directories containing the ouput of the different used tools -h. --help print this help and exit

- 5 Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- 1vbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Quelques incohérences relevées

- Lyon 3 nœuds possèdent deux disques durs de 73Go au lieu d'un seul
- Nancy un nœud possède une carte Infiniband différente du reste du cluster
- Orsay un grand nombre de nœuds du *Gdx* possède une fréquence de CPU différente
- **Sophia** les nœuds du *cluster Sol* n'ont qu'une seule carte ethernet activée contre deux annoncées dans l'*OAR database*

. . .



- ⑤ Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Objectifs

Le but de ce script était de vérifier :

- La vitesse d'écriture
- La vitesse de lecture
- Le nombre d'opérations

Objectifs

Le but de ce script était de vérifier :

- La vitesse d'écriture
- La vitesse de lecture
- Le nombre d'opérations

Objectifs

Le but de ce script était de vérifier :

- La vitesse d'écriture
- La vitesse de lecture
- Le nombre d'opérations

- 5 Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Langage Perl

- Outils Unix
 - free : pour récupérer la taille de la mémoire ram (nécessaire pour bonnie)
 - ssh : pour faire les tests et l'installation de bonnie sur les nœuds
 - Bonnie++: pour effectuer les tests sur les disques durs. on utilise le double de la taille de la mémoire ram pour le test. Par exemple pour 16Go de ram on aura :
 - bonnie++ -s 32768 -d /tmp -m griffon-92.nancy.grid5000.fr -u root

- Langage Perl
- Outils Unix
 - free : pour récupérer la taille de la mémoire ram (nécessaire pour bonnie)
 - ssh: pour faire les tests et l'installation de bonnie sur les nœuds
 - Bonnie++: pour effectuer les tests sur les disques durs. on utilise le double de la taille de la mémoire ram pour le test. Par exemple pour 16Go de ram on aura :

```
bonnie++ -s 32768 -d /tmp -m griffon-92.nancy.grid5000.fr -u root
```

- Langage Perl
- Outils Unix
 - free : pour récupérer la taille de la mémoire ram (nécessaire pour bonnie)
 - ssh: pour faire les tests et l'installation de bonnie sur les nœuds
 - Bonnie++: pour effectuer les tests sur les disques durs. on utilise le double de la taille de la mémoire ram pour le test. Par exemple pour 16Go de ram on aura:

```
bonnie++ -s 32768 -d /tmp -m griffon-92.nancy.grid5000.fr -u root
```

- Langage Perl
- Outils Unix
 - free : pour récupérer la taille de la mémoire ram (nécessaire pour bonnie)
 - ssh : pour faire les tests et l'installation de bonnie sur les nœuds
 - Bonnie++: pour effectuer les tests sur les disques durs. on utilise le double de la taille de la mémoire ram pour le test. Par exemple pour 16Go de ram on aura:

bonnie++ -s 32768 -d /tmp -m griffon-92.nancy.grid5000.fr -u root

- Langage Perl
- Outils Unix
 - free : pour récupérer la taille de la mémoire ram (nécessaire pour bonnie)
 - ssh : pour faire les tests et l'installation de bonnie sur les nœuds
 - Bonnie++: pour effectuer les tests sur les disques durs. on utilise le double de la taille de la mémoire ram pour le test. Par exemple pour 16Go de ram on aura :

```
bonnie++ -s 32768 -d /tmp -m griffon-92.nancy.grid5000.fr -u root
```

- 5 Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Fonctionnement

Algorithme:

- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- Récupération de la liste des nœuds réservés
- Création de processus fils (un par nœud)
- Chaque fils exécute les actions suivantes sur son nœud avec ssh :
 - il installe Bonnie++
 - il récupère la taille de la mémoire ram
 - il exécute la commande bonnie
- Le père attend la fin des processus fils et formate les données comme l'a demandé l'utilisateur



- ⑤ Problématique
- 6 lvcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Utilisation du script ivbon :

```
Ivbon - copyright (c) 2010 Guillaume Delourmel delourmel_guillaume@yahoo.fr>
Script to test all the hard disk drive of the nodes on a cluster
Usage : ivbon [OPTIONS]...
-f. --file [FILE] file which contains the list of node to test
-i. --install automatically install bonnie++ on nodes (bonnie++ is required)
-y. -yaml output test as yaml
-r. --remove end temporary files create by the script
-print the result in the file in YAML format, default is bonnie.txt
-h. --help print this help and exit
```

• Exemple de sortie au format texte :

```
Average speed of writing: 60392.3
Average speed of reading: 86875.3
Average number of operations: 167.1
                Node
                                                                         |Number of operations
                                         IWriting
                                                         | Reading
griffon-92.nancy.grid5000.fr
                                         44509
                                                         77547
                                                                         161.0
griffon-90.nancy.grid5000.fr
                                         45851
                                                         176340
                                                                         1167.6
griffon-91.nancy.grid5000.fr
                                         90817
                                                         1106739
                                                                         172.6
```

Exemple de sortie au format YAML :

```
Average_speed_of_writing: 55510
Average_speed_of_reading: 67703.7
Average_number_of_operations: 195
grelon-88.nancy.grid5000.fr
writing: 54096
reading: 66904
number_of_operations: 195.0
grelon-89.nancy.grid5000.fr
writing: 56154
reading: 66971
number_of_operations: 193.3
grelon-87.nancy.grid5000.fr
writing: 56280
reading: 69236
number_of_operations: 196.8
```

- ⑤ Problématique
- Ivcmp
 - Outils utilisés
 - Algorithme
 - Options disponibles
 - Incohérences relevées
- Ivbon
 - Objectifs
 - Outils utilisés
 - Fonctionnement
 - Utilisation
- 8 Problèmes rencontrés



Changement du format de sortie de l'outil oarnodes à trois reprises

Parallélisation complète du script lvcmp impossible

Bug du routeur RENATER

Changement du format de sortie de l'outil oarnodes à trois reprises

Parallélisation complète du script lvcmp impossible

Bug du routeur RENATER

Changement du format de sortie de l'outil oarnodes à trois reprises

Parallélisation complète du script lvcmp impossible

Bug du routeur RENATER

Changement du format de sortie de l'outil oarnodes à trois reprises

Parallélisation complète du script lvcmp impossible

Bug du routeur RENATER

Les réseaux rapides (Infiniband) Les réseaux rapides (Myrinet) MPI : La communication Historique de MPI Les implémentations de MPI

Partie III

Les technologies liées aux clusters

Les réseaux rapides (Infiniband)

Les réseaux rapides (Myrinet) MPI : La communication Historique de MPI Les implémentations de MPI

- ① Les réseaux rapides (Infiniband)
- Les réseaux rapides (Myrinet)
- MPI : La communication
- 12 Historique de MPI
- Les implémentations de MPI

Infiniband

- Protocole libre, supporté par défaut par les noyaux Linux récents
- De 10Gbps à 20Gbps
- Propose un mode TCP/IP sur Infiniband, pour la compatibilité
- Peut être relié à des câbles cuivrés ou des brins de fibre optique
- De plus en plus utilisé par les supercalculateurs





Les réseaux rapides (Infiniband) Les réseaux rapides (Myrinet) MPI : La communication Historique de MPI Les implémentations de MPI

- Les réseaux rapides (Infiniband)
- Les réseaux rapides (Myrinet)
- MPI : La communication
- 12 Historique de MPI
- Les implémentations de MPI

Myrinet

- Protocole propriétaire conçu par Myricom
- Technologie destinée aux clusters
- Jusqu'à 10Gbps de débit depuis 2006
- Une latence exemplairement faible
- Un coût important (deux brins de fibre optique par carte, commutateurs)
- De moins en moins de supercalculateurs utilisent Myrinet





Les réseaux rapides (Infiniband) Les réseaux rapides (Myrinet) MPI : La communication Historique de MPI Les implémentations de MPI

- ① Les réseaux rapides (Infiniband)
- Les réseaux rapides (Myrinet)
- MPI : La communication
- Historique de MPI
- Les implémentations de MPI

Message Passing Interface

- Initialement prévue pour le C/C++ et Fortran.
- Le Forum MPI, constante évolution.
- Portabilité, multi-plateforme.
- Prédestiné au monde du HPC.
- Des librairies et fonctions
 - Communicateurs
 - Fonctions point à point
 - Fonctions collectives
 - Types dérivés



MPI : Fonctionnement (1/3)

Lancement du même programme depuis le frontal.




mpicc mpirun



Frontal

MPI : Fonctionnement (2/3)


Lancement en parallèle sur chaque nœud.



MPI : Fonctionnement (3/3)

En fonction du rang, orientation différente.





- 9 Les réseaux rapides (Infiniband)
- Les réseaux rapides (Myrinet)
- MPI : La communication
- Mistorique de MPI
- Les implémentations de MPI

MPI: Historique

- Juin 1994 : la version 1.0 de MPI est lancée.
- Juin 1995 : apparition de la version 1.1.
- 1997 : mise en conformité et version 1.2.
- Juillet 1997 : version 2.0 ajouts de fonctionnalitées.
- Septembre 2008 : clarifications et version 1.3.
- Juin 2008 : clarification en vue de la version 2.1.
- 2009 : corrections, version 2.2.
- Futur 2010 : **version 3.0**, et nouvelles fonctionnalités



- ① Les réseaux rapides (Infiniband)
- Les réseaux rapides (Myrinet)
- MPI : La communication
- 12 Historique de MPI
- 13 Les implémentations de MPI

Implémentations

Il existe trois principales implémentations de MPI2.

- LAM
 - Ancienne implémentation
 - Laisse place à OpenMPI
- OpenMPI
 - Libre et Open-Source
 - Support d'Infiniband et Myrinet (re-compilation)
- MPICH2
 - Libre et Open-Source
 - Support d'Infiniband
 - Paquet spécial Myrinet (MPICH2-MX)





- Compilation
 - Spécifique selon l'implémentation.
 - mpicc.openmpi mpicc.mpich
- Exécution
 - Spécifique selon l'implémentation et donc du site.
 - mpirun.openmpi mpirun.mpich
- Comportement
 - Différent, options non normalisées.
 - –mca btl



Tests existants
Notre programme
Le mode matrice
La sexy matrice
Le mode bissection
Les bissections consécutives
Problèmes rencontrés

Partie IV

Les tests de débits/latences

- Tests existants
- 15 Notre programme
- 16 Le mode matrice
- La sexy matrice
- 18 Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés

Les Solutions testées (1/3)



- OSU Micro-Benchmarks (OMB)
- Des tests multiples basés sur MPI

```
# OSU MPI Bandwidth Test v3.1.1
# Size Bandwidth (MB/s)
1 2.00
2 4.06
4 8.16
8 16.50
16 32.89
```

Les Solutions testées (2/3)

NetPIPE

- Network Protocol Independent Performance Evaluator
- Des tests utilisant MPI

```
adx-102
1: qdx-53
Now starting the main loop
           1 bytes 21388 times -->
                                         1.85 Mbps in
                                                             4.12 usec
           2 bytes 24249 times -->
                                          3.72 Mbps in
                                                             4.10 usec
           3 bytes
                    24408 times -->
                                          5.56 Mbps in
                                                             4.12 usec
           4 bytes
                   16199 times -->
                                          7.46 Mbps in
                                                             4.09 usec
```

Les Solutions testées (3/3)

- Les Tests alternatifs
 - Infiniband
 - Myrinet



Tests existants

Notre programme

Le mode matrice

La sexy matrice

Le mode bissection

Les bissections consécutives

Problèmes rencontrés

- 14 Tests existants
- 15 Notre programme
- 16 Le mode matrice
- La sexy matrice
- 18 Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés

Notre programme : Objectifs (1/3)

- Mesurer le débit et la latence entre chaque nœud d'un cluster
- ② Donner la possibilité de faire des bissections et d'en mesurer le débit total constaté
- Oresser une matrice de ces résultats et proposer une sortie YAML
- Proposer un script de conversion du YAML en tableau HTML coloré
- Proposer un script d'automatisation des tests de bissections consécutives
- Proposer la possibilité d'en faire un graphique



Notre programme : Objectifs (2/3)

- Un unique programme d'environ mille lignes de C, utilisant la technologie MPI
- Un script Bash pour l'automatisation
- Un script Ruby pour la conversion en HTML coloré
- Un script gnuplot pour le graphique



Tests existants

Notre programme

Le mode matrice

La sexy matrice

Le mode bissection

Les bissections consécutives

Problèmes rencontrés

Notre programme : Objectifs (3/3)

```
@grelon-77:"/tests_debit_latence$ sort -u $OAR_NODEFILE > machines && mpirum.openmpi -np $(cat machines | w OAR FLOW LATENCY TESTS

-s <n>X : Message size for flow tests exchanges, in butes (with K. M, or G suffix). Min 64K, default 1M. -p <n> : Tests precision (repeats each test <n> times and make averages). Default 10. -b : Bisection, (first node of the first half with the first node of the seconde half, and so on). -rb, -r : Bisection, with random pairs. -bg, -g : Bisection, with grouplot coordinates output. -c (file) : YPML output. -h : This help.

AUTHORS : <julien@vaubourg.com>
<sebastien.badia@gmail.com>

@grelon-77:"/tests_debit_latence$
```

- 14 Tests existants
- 15 Notre programme
- 16 Le mode matrice
- 17 La sexy matrice
- 18 Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés

Le mode matrice (1/3)

Latence Temps mis par un paquet vide pour transiter (μ s) Débit Temps mis par un octet pour transiter (Mo/s)

- Un maître
- Les autres écoutent
- Ohoix d'un envoyeur, distribution des rôles
- Échanges des tests
- Répétition des tests
- **O** Changement d'envoyeur, etc.
- Sortie de la matrice



Tests existants
Notre programme
Le mode matrice
La sexy matrice
Le mode bissection
Les bissections consécutives
Problèmes rencontrés

Le mode matrice (2/3)

```
| To gdx-213
                                                                    I To gdx-214
                       | To gdx-212
                                                                                           I To 9dx-215
 From adx-212
                                                          14,400 us I
                                                                                 15.128 us I
                                                                                                        14.949 us
                                                       635.740 MoZs
                                                                              644,675 Mo/s I
                                                                                                     640,825 Mo/s
 From gdx-213
                                                                                 12,708 us I
                                                                                                        12,767 us
                                                                              669.531 Mo/s
                                                                                                     665,154 Mo/s
                                                                                                        13,196 us
 From adx-214
                                    7,665 us 1
                                668.970 Mo/s
                                                       669.591 Mo/s |------
                                                                                                     662,985 Mo/s
 From adx-215
                                    7,200 us 1
                                                           7.010 us I
                                672,025 Mo/s I
                                                       673,011 Mo/s I
                                                                              670,242 Mo/s I
Latency :
                       From 9dx-212 to 9dx-214
Max : 15.128 us
Min : 7.010 us From gdx-215 to gdx-213
Sum : 127.327 us
Avg : 10,611 us
Flow:
Max : 673.011 Mo/s
                       From adx-215 to adx-213
Min : 635.740 Mo/s
                       From 9dx-212 to 9dx-213
Sum : 7943.985 Mo/s
```

Le mode matrice (3/3)

```
9dx-213 :
 gdx-212 :
    latency : 7,343
   flow: 668,495
  9dx-214 :
    latency : 11,909
    flow: 677.445
  9dx-215 :
    latency : 11,206
    flow: 663,127
  9dx-216 :
    latency : 12,112
    flow : 671,858
adx-214 :
 9dx-212 :
    latency : 7.880
    flow + 670 927
```

- 14 Tests existants
- 15 Notre programme
- 16 Le mode matrice
- La sexy matrice
- 18 Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés

La sexy matrice

- Mise en valeur des extrémités
- Mise en valeur des quartiles remarquables

Latency flow tests (with nice colors)							
	netgdx-8	netgdx-9	netgdx-30	netgdx-4	netgdx-5	netgdx-7	
netgdx-8		159.396	156.104	156.758	157.174	156.814	MB/s
		83.458	64.325	60.236	58.532	60.856	μs
netgdx-9	154.599		155.611	157.134	153.533	155.683	MB/s
	60.415		64.945	62.573	58.591	59.39	μs
netgdx-30	173.417	174.385		151.102	172.868	170.378	MB/s
	79.823	80.562		74.387	74.649	76.795	μs
netgdx-4	179.281	178.96	157.702		175.065	173.463	MB/s
	76.592	77.105	63.217		75.09	77.2	μs
netgdx-5	180.827	158.725	155.13	156.474		158.213	MB/s
	77.176	78.905	64.719	61.488		78.297	μs
netgdx-7	179.638	159.51	155.246	157.78	156.128		MB/s
	80.955	82.481	62.609	61.405	58.663		μs

- 14 Tests existants
- 15 Notre programme
- 16 Le mode matrice
- La sexy matrice
- Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés

Le mode bissection (1/3)

- Mesurer le débit total maximum possible sur le réseau
- Détecter les nœuds qui ne sont pas connectés
- Paires formées aléatoirement



Le mode bissection (2/3)

- Un maître, les autres écoutent
- ② Distribution de tous les rôles
- Préparation et mise en attente
- Coup de feu : échanges des tests
- Répétition des tests (ensemble)
- Envoi de tous les résultats, sortie de la matrice



Tests existants
Notre programme
Le mode matrice
La sexy matrice
Le mode bissection
Les bissections consécutives
Problèmes rencontrés

Le mode bissection (3/3)

```
From gdx-212
                       | To gdx-214
                                    17,118 us I
                                 633.103 Mo/s
 From gdx-213
                       I To 9dx-215
                                   17.011 us
                                 631,490 Mo/s
Latency :
Max : 17,118 us
                        From gdx-212 to gdx-214
Min : 17,011 us
                        From gdx-213 to gdx-215
Sum : 34,130 us
Avg : 17.065 us
Flow:
Max : 633.103 Mo/s
                        From gdx-212 to gdx-214
Min : 631.490 Mo/s
                        From 9dx-213 to 9dx-215
Sum : 1264.593 Mo/s
Avg : 632,297 Mo/s
```

(YAML possible)




- 14 Tests existants
- 15 Notre programme
- 16 Le mode matrice
- La sexy matrice
- 18 Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés

Les bissections consécutives (1/2)

- Mesurer la charge du réseau en fonction du nombre de nœuds qui communiquent
- Comparer les performances entre les types de réseaux
- Comparer les débits théoriques avec les débits réels
- Détecter les goulots d'étranglement



Les bissections consécutives (2/2)



- 14 Tests existants
- 15 Notre programme
- 16 Le mode matrice
- La sexy matrice
- 18 Le mode bissection
- Les bissections consécutives
- 20 Problèmes rencontrés



Implémentations de MPI différentes selon les clusters

Impossibilité de faire communiquer les nœuds en MPI par SSH

Erreurs dûes à la compilation des implémentations

Absence de MPI sur certains clusters

Pas de support des réseaux rapides partout



Implémentations de MPI différentes selon les clusters

Impossibilité de faire communiquer les nœuds en MPI par SSH

Erreurs dûes à la compilation des implémentations

Absence de MPI sur certains clusters

Pas de support des réseaux rapides partout



Implémentations de MPI différentes selon les clusters

Impossibilité de faire communiquer les nœuds en MPI par SSH

Erreurs dûes à la compilation des implémentations

Absence de MPI sur certains clusters

Pas de support des réseaux rapides partou



Implémentations de MPI différentes selon les clusters

Impossibilité de faire communiquer les nœuds en MPI par SSH

Erreurs dûes à la compilation des implémentations

Absence de MPI sur certains clusters

Pas de support des réseaux rapides partoui



Tests existants
Notre programme
Le mode matrice
La sexy matrice
Le mode bissection
Les bissections consécutives
Problèmes rencontrés

Problèmes rencontrés

Implémentations de MPI différentes selon les clusters

Impossibilité de faire communiquer les nœuds en MPI par SSH

Erreurs dûes à la compilation des implémentations

Absence de MPI sur certains clusters

Pas de support des réseaux rapides partout



Partie V

Un environnement rapide



Infiniband

- Chargement des modules
- Mise à jour vers un noyau récent
- Installation de OpenMpi
- Création d'un tutoriel PDF complet (installations, mise à jour des paquets)





Myrinet (1/2)

- Patch du noyau
- Indisponible dans les paquets Debian
- Pas de **service** pour lancer la création de l'interface
- Pilotes propriétaires (à demander)



Myrinet (2/2)

- Recupération des pilotes
- Recompilation d'un noyau récent
- Construction d'un paquet Debian du noyau
- Construction d'un paquet des drivers Myrinet
- Construction d'un paquet OpenMPI Myrinet
- Création d'un service de gestion du support de Myrinet
- Création d'un tutoriel PDF complet (installations, mise à jour des paquets)





Impossible de récupérer MPICH2-MX

Installation de drivers propriétaires dans l'environnement (sic)

Environnement impossible à déployer sur certains clusters

Déploiements hasardeux, de façon générale, avec kadeploy3

Mise à jour du noyau problématique (trois déploiements)



Partie VI

Problèmes généraux

Problèmes généraux

Sortie en SSH impossible depuis l'IUT

Documentation Grid5000 pas toujours à jour (documentation de l'outil kaconsole3 pour Grenoble par exemple)

Maintenances fréquentes sur les *clusters* d'où des difficultés parfois à travailler correctement

Problèmes généraux

Sortie en SSH impossible depuis l'IUT

Documentation Grid5000 pas toujours à jour (documentation de l'outil kaconsole3 pour Grenoble par exemple)

Maintenances fréquentes sur les *clusters* d'où des difficultés parfois à travailler correctement



Problèmes généraux

Sortie en SSH impossible depuis l'IUT

Documentation Grid5000 pas toujours à jour (documentation de l'outil kaconsole3 pour Grenoble par exemple)

Maintenances fréquentes sur les *clusters* d'où des difficultés parfois à travailler correctement



Partie VII

Conclusion

Conclusion (1/4)

Objectifs remplis:

- Inventaire automatique du matériel
- Tests des disques durs
- Tests des débits et latences des nœuds d'un cluster (vérification des correctes interconnexions)
- Bissections sur les clusters
- Support des réseaux rapides dans un environnement personnalisé



Conclusion (2/4)

Pour cela, les administrateurs bénéficient à présent :

- De plusieurs nouveaux outils entièrement paramétrables
- De sorties YAML, de matrices non-parsables, de matrices colorées, de graphiques, de tutoriels PDF

Nous avons aussi apporté :

- De nombreux problèmes de matériel détectés et vérifiés
- De nombreux bugs rapportés



Conclusion (3/4)

D'ores et déjà une **vidéoconférence** a eu lieu au LORIA (siège nancéen de Grid5000) pour un administrateur d'un autre site intéressé par le script d'inventaire.



Conclusion (4/4)

Bénéfices personnels

Découverte du monde des grilles de calcul et des clusters

Approfondissement des langages C, Perl, Ruby

Découverte de la programmation en MPI

Organisation pour un travail en équipe conséquent

Et comme c'est bientôt Pâques



(Easter egg inside)