Les clusters de calcul

Sébastien Badia
Guillaume Delourmel
Luc Didry
Julien Vaubourg

LP ASRALL
Année universitaire 2009-2010

Université Nancy 2
IUT Nancy-Charlemagne

Conventions typographiques

Toute portion de code importante sera éditée comme suit :

```
print "42\n";
```

Les chemins des répertoires et les exemples de code seront écrits avec la fonte « `Machine à écrire` » de LaTeX :
`/space/www/`

Les mots dont vous trouverez la définition dans le glossaire seront signalés ainsi :
grille de calcul

Les références aux livres présents dans la bibliographie seront signalés ainsi :
Exemple [8]

Dans la version électronique de ce rapport, les liens hypertexte, de même que les liens internes au document, sont actifs et sont donc cliquables. Ces liens se repèrent grâce à la couleur de leur police :
Une url : http://www.grid5000.fr
Un lien interne : 1.1
Un lien vers la bibliographie : [3]

Citations

Les citations présentes à chaque paragraphe sont extraites de la page de l'encyclopédie en ligne *Wikipédia* sur la loi de Murphy [1].
Ces citations n'ont qu'un but humoristique.

1. http://fr.wikipedia.org/wiki/Loi_de_Murphy

Table des matières

Chapitre 1

Introduction

Nul n'est parfait. . .surtout pas les autres.

1 Calcul Haute Performance

1.1 Définition

Le calcul haute performance (en anglais High Performance Computing (HPC)) provient de l'utilisation d'importantes ressources de calcul, que ce soit par l'emploi de supercalculateurs, d'une grille de calcul, de clusters ou d'ordinateurs ordinaires mis en réseau (à l'instar des clusters, mais sans l'homogénéité matérielle de ceux-ci. Un bon exemple d'une telle structure est le projet *SETI@home*[1]).

1.2 Les enjeux du calcul haute performance

Alors que l'on pourrait penser que le HPC est réservé à la recherche ou aux très grandes entreprises, de plus petites structures peuvent en avoir l'usage et les moyens. Ainsi une entreprise de taille moyenne de construction de camions a pu déterminer grâce au HPC qu'en supprimant les pare-boues de ses produits, cela permettait de réduire la résistance à l'air et d'économiser 400$ par an et par camion en essence [3]. Si ce chiffre peut sembler ridicule, imaginez une entreprise possédant une flotte de 1000 véhicules et considérez l'économie réalisée. Depuis, cette entreprise utilise de façon régulière l'HPC pour améliorer l'efficacité du design de ses camions, qui devinrent encore plus économes.

Le HPC est aujourd'hui utilisé dans des domaines variés, allant des essais de combustion à la modélisation climatique, en passant par la simulation d'explosions nucléaires ou la recherche médicale [2]. Cette technologie permet de s'affranchir de limites telles que le temps, par exemple en proposant des simulations astronomiques, donnant des résultats en peu de temps, comparé aux centaines de millions d'années d'observation que ceux-ci auraient demandées [4]. Une autre limite que nous pouvons désormais dépasser grâce au HPC est celle de la taille : de l'infiniment petit de la fusion de l'atome à l'infiniment grand des galaxies. . .

1. http://setiathome.berkeley.edu/

1.3 Historique [4]

On peut faire remonter le calcul haute performance aux machines mécaniques de PASCAL au XVII^{ème} siècle (la *pascaline*) ou celle de BABBAGE au XIX^{ème} siècle. Puis sont apparus les ordinateurs actuels fondés sur l'architecture de VON NEUMANN (1945) et exploitant les possibilités des semi-conducteurs (1956).

Entre ces périodes, on a pu quantifier le coût d'une opération arithmétique typique de base. Ce coût a décru d'un facteur 10^{15} en passant de la première machine aux ordinateurs de 2006 dont la puissance s'exprimait en téraflops, soit 10^{12} opérations par seconde. Au milieu des années 1970, la société *Cray* développa une architecture permettant d'envisager un coût d'investissement d'un million de dollars pour un million d'opérations par seconde. Trente plus tard, les progrès technologiques des circuits électroniques et de la science de la simulation ont permis de multiplier le nombre d'opérations par un million pour un coût équivalent.

Le supercalculateur vainqueur du *top 500*[2] possède une puissance de plus de 1759 téraflops.

La puissance de calcul ne cesse de croître et certains pensent que nous pourrons atteindre l'exaflop[3] d'ici 2015.

2 Grid5000

2.1 Objectif de la création

L'objectif de la création de Grid5000 est d'atteindre 5000 processeurs sur les différents sites. Cela permettra d'avoir les moyens d'effectuer des recherches dans le domaine des grilles. Il sera ainsi possible d'effectuer des tests réels plutôt que de ne présenter que des résultats de simulation.

2.2 Organisation

Le projet Grid5000 est réparti sur différents sites qui sont interconnectés avec le réseau Réseau National de télécommunications pour la Technologie l'Enseignement et la Recherche (RENATER) (voir figure 1.1, page 6).

Les sites sont composés de un ou plusieurs clusters, comme le site de Nancy avec Griffon et Grelon. Chaque site est géré par son propre administrateur, ce qui entraîne une hétérogénéité de configuration sur les différents sites. Par exemple, les frontends des différents sites qui ne disposent pas des mêmes librairies : ainsi sur Nancy nous ne pouvions pas faire l'export du résultat d'une commande au format *JSON* alors que l'option était proposée, ou encore le fait qu'on ne puisse pas accéder directement au site de Nancy et que l'on doive passer par un site comme Lyon qui permet une entrée à partir de l'extérieur du réseau.

2. Projet de classification des 500 premiers supercalculateurs connus au monde. http://top500.org

3. 10^{18} opérations par seconde

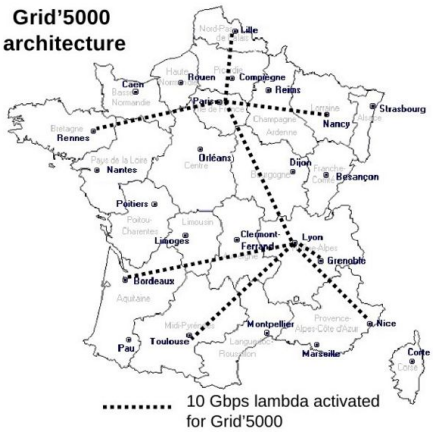

FIGURE 1.1 – Répartition des sites Grid5000 sur le territoire français

3 Objectifs

L'objectif de ce projet tuteuré était de développer une suite d'outils permettant de vérifier la conformité d'un cluster acheté par rapport à l'appel d'offres auquel il fait suite et de vérifier les performances réseau et ainsi de vérifier la bonne interconnexion des nœuds.

Il s'agissait en particulier de permettre un inventaire matériel automatique des nœuds et d'effectuer un ensemble de benchmarks portant sur le stockage, le réseau en Ethernet et le réseau rapide (cartes Infiniband et Myrinet)

Chapitre 2

L'environnement de Grid5000

La caractéristique la plus constante de l'informatique
est la capacité des utilisateurs à saturer
tout système mis à leur disposition.

1 Les outils OAR

1.1 Réservations

OAR est une collection d'outils développée par le laboratoire IMAG [1] de l'Institut National de Recherche en Informatique et Automatique (INRIA) permettant de gérer un cluster de machines. Il fonctionne avec *Perl* à l'aide de *MySQL* et prend en charge le mécanisme de réservation ainsi que l'utilisation massivement simultanée des machines en cluster. Grid5000 fait partie des cinq partenaires de OAR.

Lorsqu'un utilisateur souhaite accéder au projet depuis l'extérieur, il doit passer par une machine pare-feu d'un des neufs sites de France, parmi celles qui acceptent ce genre de connexion. Une fois ce pare-feu passé grâce à l'identification par clé *SSH*, c'est un frontal qui s'offre à l'utilisateur. Celui-ci est pourvu d'un espace qui lui est dédié. Cet espace se retrouvera partout où l'utilisateur ira grâce à un montage Network File System (NFS), dans n'importe quelle machine de n'importe quel cluster, tant qu'il ne quitte pas le site. En effet, les espaces personnels ne sont pas encore partagés d'un site à l'autre, ce qui pose divers problèmes d'harmonisation et de réplication des données. Sur ce frontal, les possibilités sont très limitées et se cantonnent surtout à utiliser les outils OAR. La première chose que ces outils lui permettront de faire, c'est de réserver des nœuds. Dans le jargon des clusters, cela signifie réserver un ensemble de machines physiques, pour pouvoir exécuter des actions dessus et de façon parallèle. Une réservation se fait avec son nom d'utilisateur et pour un temps donné. Il est également possible de préciser le

1. Institut d'Informatique et de Mathématiques Appliquées de Grenoble

nombre de nœuds ou de processeurs souhaités. Par le biais de filtres SQL, d'autres options sont offertes : réservation sur un cluster en particulier, sélection de nœuds possédant un matériel spécifique, etc. Si la requête trouve les machines correspondantes et que celles-ci sont libres dans l'intervalle de temps demandé, l'utilisateur est automatiquement connecté sur la première des machines de sa réservation.

Un petit tour sur les outils de monitoring des clusters (parmi eux un Ganglia, un Nagios et un diagramme de Gantt des réservations) lui indique par un rectangle de couleur le nombre de machines réservées ainsi que la durée de la réservation qui porte son nom d'utilisateur. L'environnement proposé par défaut est appelé l'environnement de développement. Celui-ci lui permettra d'exécuter des programmes qui concerneront l'ensemble des machines de sa réservation, auxquelles il peut accéder sans limite par *SSH*. Le principal intérêt de cet environnement est d'exécuter des programmes *MPI*. Nous verrons cette norme par la suite, mais retenez que c'est un moyen de faire travailler toutes les machines de la réservation en les faisant communiquer facilement.

Cet environnement de développement, différent sur chaque site et parfois même d'un cluster à l'autre, est stocké sur une partition réservée sur chacun des nœuds. L'espace de l'utilisateur est monté en NFS sur les nœuds réservés.

1.2 Déploiements

Le déploiement consiste à installer son propre système d'exploitation sur tous les nœuds de la réservation. Dans ce cas, la réservation doit être prise en indiquant ses intentions lors de l'appel de la commande. Des systèmes préparés sont ensuite disponibles dans la base de données des sites (qui diffère d'un site à l'autre). Il est possible d'installer un de ces systèmes, de le modifier en ajoutant ou en supprimant des programmes, des données, et de compresser le tout pour en faire un environnement personnalisé, qui pourra être déployé sur une future réservation. Lorsque l'utilisateur réserve des nœuds pour un déploiement, il est redirigé vers un environnement spécial de déploiement sur le frontal. Il pourra alors demander le déploiement d'un système sur toutes les machines, qui redémarreront sur une partition différente après avoir effectué l'installation du système. Ce déploiement est géré principalement par `kadeploy3`, un outil également développé par l'INRIA.

Pour constater le redémarrage de la machine et éventuellement détecter les problèmes qui peuvent survenir à cause de l'environnement, il est possible de visualiser directement la séquence de lancement du *BIOS*, avant même que le noyau Linux ne soit démarré. `Kaconsole3` permet ceci, grâce à un contrôleur matériel et l'outil `telnet`.

2 Les réseaux rapides

Au sein du projet Grid5000, nous constatons déjà que beaucoup de choses sont hétérogènes. Mais le plus marquant est peut-être la diversité des moyens de communications au sein des clusters. Selon le site ou le cluster choisi, il est en effet possible de communiquer de cinq façons différentes :

1. TCP/IP via une infrastructure Ethernet

2. TCP/IP via une infrastructure Infiniband
3. TCP/IP via une infrastructure Myrinet
4. Infiniband via une infrastructure Infiniband
5. Myrinet via une infrastructure Myrinet

2.1 Infiniband

Avec la couche standard OpenIB, Infiniband est une technologie libre et open-source supportée directement par les noyaux Linux récents. C'est un modèle de communication très performant et très économique, puisqu'il peut fonctionner sur des câbles cuivrés. Libre, il a l'avantage non négligeable d'être directement supporté par certains logiciels, directement dans les paquets de Debian.

Du fait de son implémentation libre, l'Infiniband est aujourd'hui presque incontournable dans le monde du HPC. L'implémentation dans le projet Grid5000 se fait à travers des cartes Mellanox, nommées Host Channel Adapter (HCA). Celles-ci peuvent fonctionner à 10 Gb/s comme à 20 Gb/s.

Le protocole Infiniband peux être implémenté à deux niveaux différents :

- De façon native, en utilisant le protocole *VERBS*.
- Avec une surcouche logicielle comme :
- – *IPoIB* : protocole IP sur Infiniband, il permet « d'émuler »une carte Ethernet avec une carte Infiniband.
  - SCSI RDMA Protocol (SRP) : permet d'encapsuler des trames *SCSI* à travers l'Infiniband.
  - Socket Direct Portocol (SDP) : mise en place d'une couche *socket* au dessus de l'Infiniband.

Il est évident de rappeler que l'utilisation de ces surcouches au protocole Infiniband dégradent les performances. Pour des performances maximales, il faut donc utiliser de préférence la couche native *VERBS*.

Question de Requests For Comments (RFC) Le protocole Inifiniband étant un standard, il est intéressant de souligner quelques RFC, dont les suivantes sont les plus intéressantes :

1. RFC4392 - IP over InfiniBand (*IPoIB*) Architecture
2. RFC4391 - *Transmission of IP over InfiniBand*
3. RFC4755 - *IP over InfiniBand : Connected Mode*

http://www.rfc-editor.org/cgi-bin/rfcsearch.pl

2.2 Myrinet

Ce qui n'est pas le cas de Myrinet. En effet, Myrinet est développé par la société Myricom. Dans des paquets comme ceux des implémentations *MPI*, on ne trouve donc pas le support natif de cette technologie. Pour faire du vrai Myrinet sur du réseau Myrinet, il faut donc recompiler ces paquets. Enfin, les drivers Myrinet ne peuvent s'obtenir qu'en les réclamant par courriel à la société Myricom et en justifiant d'un numéro de client. On

constate ici les problèmes liés aux technologies propriétaires qui nous ont fait perdre énormément de temps. Les infrastructures sont plus coûteuses puisque chaque nœud connecté en Myrinet doit avoir à disposition deux câbles en fibre optique, un pour les entrées et l'autre pour les sorties.

Chapitre 3

Vérification automatique du matériel

En cas de doute, videz votre chargeur.

Étant donné que la mailing list des utilisateurs de Grid5000 est souvent rédigée en anglais, nous avons jugé bon de rédiger les commentaires de nos scripts dans la langue de Shakespeare, ainsi que tous les différents messages (erreurs, usage, etc.).

Il est à noter que notre travail a évolué de façon dynamique : en effet, au fur et à mesure, M. Nussbaum a affiné ses demandes. Il nous était d'abord demandé de vérifier la véracité de l'OAR Database, puis de comparer les nœuds entre eux en créant des groupes partageant le même matériel. Enfin s'est greffé le benchmark des disques durs.

1 Inventaire automatique

1.1 Objectifs

Les clusters du projet Grid5000 sont achetés via des appels d'offre mais il arrive que le matériel livré ne soit pas totalement homogène : disques durs de tailles équivalentes mais de modèles différents, cartes de réseau rapide de modèles différents, etc. Le matériel peut aussi tomber en panne sans toutefois faire tomber le nœud (une barrette de ram qui cesse de fonctionner par exemple).

Comme il est difficilement envisageable pour les administrateurs de tester individuellement chaque nœud à la livraison et de façon périodique, il nous a été demandé de créer un script permettant un inventaire automatique des nœuds réservés et de les comparer entre eux pour vérifier l'homogénéité du cluster sur une liste de critères prédéfinis.

De plus, un certains nombre d'informations sur les nœuds sont entrées dans une base de données (l'*OAR Database*) lors de la mise en service du cluster. L'administrateur, pour des raison évidentes de lourdeur de la procédure, se contente de récupérer les informations d'un nœud et de les dupliquer autant de fois qu'il y a de machines dans le cluster. Cela peut poser des problèmes de véracité de la base de données si le matériel n'est pas parfaitement homogène, c'est pourquoi notre script vérifie aussi la concordance à l'*OAR Database*.

1.2 Choix des outils

Langage

Nous avons choisi *Perl* comme langage de script. En effet, nous connaissions bien ce langage, le *Bash* n'était pas adapté pour les fonctionnalités que nous voulions implémenter (tables de hashage, lecture et écriture de *XML*, de *YAML*...), seul Guillaume possédait des connaissances (basiques) de *Python* et nous venions seulement de commencer les cours de *Ruby*.

Outils *Unix*

Nous avons utilisé différents outils *Unix* pour récupérer les informations que nous devions vérifier (voir tableau 3.1 page 12 pour la concordance outil <–> informations).

Si certains outils comme `uname` se sont vite imposés pour leur simplicité, le choix de `lshw` a été plus compliqué : nous avions retenu plusieurs programmes pour nous apporter les informations utiles :

- `lshw`
- `lspci`
- `ocsinventory`
- `hwinfo`

`lspci` a tout de suite été écarté en raison du peu d'informations fournies (mais il s'est révélé utile pour d'autres données).

`ocsinventory` a de même été mis hors concours mais pour sa dépendance à un serveur web et à une interface graphique pour récupérer les résultats.

`lshw` l'a emporté sur `hwinfo` grâce à sa sortie au format XML, ce qui nous a permis d'exploiter aisément ses résultats.

Outil	Information récupérée
uname -nm	Nom du cluster du nœud Nom (hostname) du nœud
lspci	Présence des cartes réseau rapide Infiniband et Myrinet Modèles des cartes réseau rapide Infiniband et Myrinet le cas échéant Interface du disque dur (sata, ide...)
cat /proc/cpuinfo	Nombre de cœurs des CPU
lshw -xml -C disk -C memory -C network -C processor	Type de cpu Quantité de mémoire vive Modèle de disque dur Taille du disque dur (ou le cumul des disques en RAID) Fréquence des CPU
ifconfig	Nombre de cartes ethernet activées

TABLE 3.1 – Outils *Unix* utilisés et informations récupérées

Nous avons utilisé un appel système à `ssh` pour récupérer les informations fournies par les outils *Unix*. En effet, il aurait été difficile d'utiliser le module *Perl* `Net::SSH::Perl`

car nous avons installé localement tous les modules *Perl* pour garantir la portabilité sur tous les sites et ce module ci nécessite bien trop de dépendances.

Modules *Perl*

Nous utilisons plusieurs modules *Perl*, installés dans le répertoire du script afin que celui-ci soit indépendant du site où il est utilisé.

Les modules utilisés sont :

- `YAML` : pour la récupération des informations de l'*OAR Database* en *YAML*
- `Data::Dumper` : pour convertir le format *YAML* en information exploitable
- `XML::Simple` : pour la récupération des information envoyées par `lshw`
- `POSIX ":sys_wait_h"` : nécessaire pour la gestion des forks, il s'agit d'un module du cœur de *Perl* donc nous n'avons pas eu à l'installer

Options du script

Nous avons implémenté quelques options :

`-f`, `--file [FILE]` : spécifie le fichier contenant la liste des nœuds déployés. Par défaut, on utilisera le fichier défini par la variable d'environnement `$OAR_FILE_NODES`.

`-o`, `--output [FILE]` : permet de spécifier un fichier dans lequel écrire la sortie *YAML* (avec protection contre la réécriture)

`-p`, `--parameter CRITERION` : permet de ne comparer les nœuds que sur certains critères

`-i`, `--install` : installe automatiquement `lshw` sur tous les nœuds déployés

`-r`, `--remove` : supprime automatiquement les répertoires contenant les fichiers des informations des nœuds une fois le script terminé

`-h`, `--help` : affiche un message d'aide

1.3 Algorithme

Le fonctionnement du programme est simple :

1. Récupération de la liste des nœuds déployés par le fichier spécifié ou par la variable d'environnement `$OAR_FILE_NODES`
2. Pour chaque nœud, en forkant, nous installons `lshw` si l'option est activée et nous récupérons les sorties des outils *Unix* dans des fichiers
3. Pour chaque nœud, de façon séquentielle, nous récupérons les informations de l'*OAR Database* et des fichiers des outils *Unix* dans des tables de hashage puis nous comparons ces deux types d'informations
4. Comparaison des nœuds entre eux
5. Sortie au format *YAML* sur la sortie standard ou dans un fichier
6. Affichage des incohérences au niveau de l'*OAR Database*

1.4 Exemple d'utilisation

Nous lançons le script avec :

```
./ivcmp
```

Nous récupérons sur la sortie standard :

```
--- Notice that the printed value are from Unix tools, not from OAR database ---
1 :
  cluster : grelon
  cpuarch : x86_64
  cpucore : 2
  cpufreq : 1.6
  cputype : Intel(R) Xeon(R) CPU 5110 @ 1.60GHz
  diskmodel : ST3808110AS
  disksize : 80
  disktype : sata
  ib10g : ~
  ib10gmodel : ~
  ib20g : ~
  ib20gmodel : ~
  memnode : 2048
  myri10g : ~
  myri10gmodel : ~
  myri2g : ~
  myri2gmodel : ~
  nodes :
    grelon-102.nancy.grid5000.fr : ~
    grelon-103.nancy.grid5000.fr : ~
    grelon-104.nancy.grid5000.fr : ~
------ The Oar database cpufreq information of the node grelon-103.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-103.nancy.grid5000.fr is not
     the same as we check on the node ------
      OAR database : 2          Unix tools : 1
------ The Oar database cpufreq information of the node grelon-104.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-104.nancy.grid5000.fr is not
     the same as we check on the node ------
      OAR database : 2          Unix tools : 1
------ The Oar database cpufreq information of the node grelon-102.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-102.nancy.grid5000.fr is not
     the same as we check on the node ------
      OAR database : 2          Unix tools : 1
```

Il faut noter que les messages d'incohérence relatifs à l'*OAR Database* ainsi que le message d'avertissement ne sont pas écrits dans la sortie fichier lorsqu'elle est demandée. Ces messages sont toujours dirigés vers `$STDOUT`

1.5 Relevé d'incohérences

Nous n'avons pas noté toutes les incohérences ressorties lors des tests car cela serait trop long.

Bordeaux

- bordereau-22 : ce nœud ne possédait que 3Go de mémoire vive au lieu de 4
- bordereau-4 et bordereau-7 n'ont pas le même modèle de disque dur que les autres nœuds : `WDC WD800ABJS-23` au lieu de `Hitachi HDS72168`

Grenoble

- genepi-29 : bien que le modèle du CPU soit le même (`Intel(R) Xeon(R) CPU E5420 @ 2.50GHz`), `lshw` nous donne 2GHz au lieu des 2.5GHz calculés pour tous les autres nœuds.

Lille

- cluster Chuque : les disques durs sont de type `sata` alors que l'*OAR Database* annonce de l'`ide`. De plus il y deux modèles différents de disques durs : `WDC WD800JD-23JN` et `Maxtor 6Y080M0`
- cluster Chti : deux cartes ethernet sont activées contre une annoncée
- chti-1 : 3Go de mémoire vive contre 4Go pour le reste du cluster
- chicon-14 : modèle de disque dur différent des autres nœuds : `WDC WD800JD-23LS` au lieu de `HDS728080PLA380`

Lyon

- capricorne-55 : possède un disque de 147 Go (deux disques de 73.5Go) au lieu de 36
- sagittaire-71, 74 et 77 : possède un disque de 147 Go (deux disques de 73.5Go) au lieu de 73

Nancy

- griffon-91 : le modèle de carte Infiniband 10g est MT25418 alors que les autres nœuds ont une carte MT26418
- grelon-17 : ce nœud possédait 1 Go de mémoire vive au lieu de 2
- cluster Grelon : les informations de l'*OAR Database* sont erronées en ce qui concerne la fréquence du CPU : au lieu des 2GHz annoncés, nous n'en relevons que 1.6. De même, le nombre de carte ethernet activées est de une carte relevée pour deux annoncées

Orsay

- cluster Gdx : l'information du nombre de cœurs par CPU est erronée sur l'*OAR Database* : 1 seul cœur par CPU relevé contre 2 annoncés
- gdx-309 et gdx-310 : la fréquence du CPU annoncée sur l'*OAR Database* (2.4GHz) est erronée : 2GHz relevés
- gdx-46 : 1Go de mémoire vive contre 2Go
- général : environ une trentaine de nœuds du cluster Gdx ont une fréquence de CPU différente du reste du cluster et il existe différents types de disques durs (environ moitié/moitié)

Rennes

- cluster Paramount : l'interface du disque dur relevée est de l'`ide` au lieu du `sata` annoncé. Ceci peut cependant provenir d'un problème du script
- cluster Paraquad : l'interface du disque dur relevée est du `sas` au lieu du `sata` annoncé.

Sophia

- cluster Sol : une carte ethernet est activée contre deux annoncées
- azur-6 : nous n'obtenons pas les mêmes informations au niveau du modèle du disque dur et de son interface par rapport au reste du cluster

– helios-52 : nous n'obtenons pas les mêmes informations au niveau du modèle du disque dur et de son interface par rapport au reste du cluster

Toulouse

Nous n'avons relevé aucun problème à Toulouse mais ceci peut provenir du fait que nous n'avons pas pu réserver un grand nombre de nœuds pour le test (28 nœuds alors que nous avions réservé près d'une centaine de nœuds sur les autres sites)

1.6 Limites du script

Afin de pouvoir comparer certaines informations avec l'*OAR Database*, nous avons été obligé de faire des arrondis sur certains chiffres, ce qui peut entraîner des faux positifs. Par exemple, à Lyon, le cluster Sagittaire (en plus des incohérences détectées plus haut) est coupé en deux groupes : un possédant un disque dur de 73Go, l'autre un disque de 74Go. Ce genre d'erreur est facilement repérable mais pourrait poser probléme dans le cadre d'un traitement automatisé des résultats.

Vous pouvez retrouver le script d'inventaire à l'annexe 1, page 46, ainsi que son README.

2 Test des disques durs

2.1 Objectif

Deux semaines avant la fin du projet, et dans la continuité de l'inventaire des nœuds, il nous a été demandé d'écrire un script pour effectuer des tests de performance sur les disques durs, car il s'agit là aussi d'une manipulation que les administrateurs ne peuvent lancer machine après machine. Cela permet ainsi de vérifier que le disque dur d'un nœud n'est pas défectueux et par exemple ne présente pas une vitesse d'écriture ou de lecture réduite par rapport aux autres nœuds.

2.2 Le script

Outils

Pour écrire ce script, nous avons utilisé le *Perl* étant donné que nous avions commencé avec ce langage pour le script de l'inventaire du matériel et que c'est celui que nous connaissions le mieux.

Pour l'accès aux nœuds réservés nous avons utilisé `ssh` qui est lancé en parallèle sur tous les nœuds. On peut ainsi effectuer les tests sur les disques durs en même temps pour que cela dure moins longtemps.

Pour effectuer les tests des disques durs, nous avons choisi d'utiliser `Bonnie++`. C'est un outil qui permet de récupérer les informations sur la vitesse d'écriture, de lecture et le nombre d'opérations effectuées par seconde sur le disque.

Pour pouvoir effectuer ces tests nous devons récupérer la taille de la mémoire ram sur chaque nœuds (nécessaire pour la taille du fichier de test). Nous utilisons pour cela l'outil `free`.

Nous avons utilisé des forks pour effectuer une parallélisation des tests, car un test seul prend déjà un temps relativement long (environ 15 minutes pour un test avec un fichier de 4G).

Algorithme

Voici le fonctionnement du programme :
- Récupération de la liste des nœuds réservés
- Pour chaque nœud en utilisant des forks :
  - On récupère la taille de la mémoire sur chaque nœud
  - On effectue le test avec la commande :

```
bonnie++ -s $ram -d /tmp -m nom_du_noeud -u root> nom_du_noeud.txt
```

- A la fin des tests nous sortons les données au format demandé.

2.3 Exemple d'utilisation

Après avoir effectué une réservation sur l'un des sites il faut lancer le script `ivbon` avec l'option `-i` pour installer `Bonnie++` lors de la première exécution. Il est ensuite possible de sélectionner le nom du fichier de sortie ainsi que son type (texte ou *YAML*).

Par exemple pour un premier lancement et pour avoir un fichier en *YAML* nommé `sortie.yml` on aura la commande suivante :

```
./ivbon -i -o sortie.yml -y
```

On récupérera alors le ficher suivant :

```
Average_speed_of_writing: 30862
Average_speed_of_reading: 66291.3
Average_number_of_operations: 205.3
grelon-33.nancy.grid5000.fr
  writing: 31076
  reading: 68539
  Number_of_operations: 207.8
grelon-34.nancy.grid5000.fr
  writing: 30361
  reading: 63508
  Number_of_operations: 208.7
grelon-35.nancy.grid5000.fr
  writing: 31149
  reading: 66827
  Number_of_operations: 199.4
```

Dans le cas où on aurait choisi une sortie texte (sans l'option -y) on aurait eu :

```
Average_speed_of_writing: 31579.3
Average_speed_of_reading: 66244.7
Average_number_of_operations: 197.9
                Node            |Writing    |Reading    |Number_of_operations
grelon-33.nancy.grid5000.fr     |31779      |68636      |204.1
grelon-34.nancy.grid5000.fr     |31197      |63308      |191.8
grelon-35.nancy.grid5000.fr     |31762      |66790      |197.7
```

2.4 Relevé d'incohérences

Bordeaux

Cluster Bordereau :

Moyenne vitesse d'écriture : 44048.9
Moyenne vitesse de lecture : 71029.6
Moyenne nombre d'opération : 202.7

Nœuds :	Anomalie	Valeur
bordereau-36	ecriture	29208
bordereau-34	ecriture	27050
bordereau-39	ecriture	5982

Nœuds :	Anomalie	Valeur
bordereau-39	nb d'opérations	160.1
bordereau-23	ecriture	30122
bordereau-24	ecriture	28309

Lyon

Cluster Capricorne :

Moyenne vitesse d'écriture : 49777.6
Moyenne vitesse de lecture : 55861.5
Moyenne nombre d'opération : 450.1

Nœuds :	Anomalie	Valeur
capricorne-4	ecriture	68743
capricorne-4	lecture	78586
capricorne-4	nb d'opérations	563.5
capricorne-6	ecriture	34964
capricorne-6	lecture	37026
capricorne-7	ecriture	38529
capricorne-7	lecture	36711
capricorne-7	nb d'opérations	640.0
capricorne-9	ecriture	73872
capricorne-9	lecture	85312
capricorne-9	nb d'opérations	667.4
capricorne-15	ecriture	74222
capricorne-15	lecture	85807
capricorne-15	nb d'opérations	667.7
capricorne-17	ecriture	68984
capricorne-17	lecture	78815
capricorne-17	nb d'opérations	544.0
capricorne-19	ecriture	35682
capricorne-19	lecture	37057

Nœuds :	Anomalie	Valeur
capricorne-21	ecriture	35215
capricorne-21	lecture	37038
capricorne-23	ecriture	36501
capricorne-23	lecture	36641
capricorne-24	ecriture	35803
capricorne-24	lecture	37219
capricorne-26	ecriture	34752
capricorne-26	lecture	36992
capricorne-28	ecriture	36053
capricorne-28	lecture	37117
capricorne-35	ecriture	35715
capricorne-35	lecture	36629
capricorne-35	nb d'opérations	399.6
capricorne-52	ecriture	36078
capricorne-52	lecture	37177
capricorne-55	ecriture	72406
capricorne-55	lecture	83734
capricorne-55	nb d'opérations	635.4

Nancy

Cluster Grelon :

Moyenne vitesse d'écriture : 36253.8
Moyenne vitesse de lecture : 66644.7
Moyenne nombre d'opération : 195.9

Nœuds :	Anomalie	Valeur
grelon-73	ecriture	54065
grelon-74	ecriture	54774
grelon-75	ecriture	55113
grelon-76	ecriture	53950
grelon-77	ecriture	51695
grelon-78	ecriture	55989
grelon-79	ecriture	53547
grelon-80	ecriture	56390
grelon-81	ecriture	54288
grelon-82	ecriture	53486

Nœuds :	Anomalie	Valeur
grelon-83	ecriture	54333
grelon-84	ecriture	55516
grelon-86	ecriture	57512
grelon-87	ecriture	55839
grelon-89	ecriture	56986
grelon-91	ecriture	59139
grelon-92	ecriture	54436
grelon-93	ecriture	53522
grelon-95	ecriture	54910
grelon-96	ecriture	54414

Cluster Griffon :
Moyenne vitesse d'écriture : 49786.5
Moyenne vitesse de lecture : 77414.2
Moyenne nombre d'opération : 162.6

Nœuds :	Anomalie	Valeur
griffon-2	ecriture	34066
griffon-15	ecriture	34349
griffon-23	ecriture	27340
griffon-45	ecriture	38831

Nœuds :	Anomalie	Valeur
griffon-85	ecriture	33027
griffon-91	ecriture	91811
griffon-91	lecture	106785

Rennes

Cluster Parадent :
Moyenne vitesse d'écriture : 47121.9
Moyenne vitesse de lecture : 75675.2
Moyenne nombre d'opération : 145.9

Nœuds :	Anomalie	Valeur
paradent-5	ecriture	30237
paradent-16	ecriture	32227
paradent-18	ecriture	28269

Nœuds :	Anomalie	Valeur
paradent-25	ecriture	33268
paradent-53	ecriture	20384
paradent-56	ecriture	29540

Sophia

Cluster Sol :
Moyenne vitesse d ecriture : 53964.1
Moyenne vitesse de lecture : 64341.2
Moyenne nombre d opération : 222.6

Nœuds :	Anomalie	Valeur
sol-11	ecriture	9068
sol-11	lecture	35121
sol-39	ecriture	21749

Nœuds :	Anomalie	Valeur
sol-40	ecriture	24894
sol-41	ecriture	31420
sol-46	ecriture	42214

Toulouse
Cluster Pastel
Moyenne vitesse d'écriture : 41999.2
Moyenne vitesse de lecture : 58396.2
Moyenne nombre d'opération : 195.2

Nœuds :	Anomalie	Valeur
pastel-30	ecriture	23820
pastel-30	lecture	39835
pastel-19	ecriture	19470

Nœuds	Anomalie	Valeur
pastel-22	ecriture	17584
pastel-22	lecture	39430
pastel-33	ecriture	29510

3 Problèmes rencontrés

Lors de la parallélisation du script d'inventaire, nous avions voulu forker au maximum mais cela nous obligeait à partager des variables entre le processus père et ses fils. Nous avons pour cela utilisé le module `IPC::Shareable` mais des problèmes de mémoire partagée sont apparus lors de tests à grande échelle (100 nœuds), ce qui nous a conduit à ne paralléliser que l'installation des outils *Unix* et la récupération de leurs résultats. L'extraction des données à partir des fichiers de résultats des outils *Unix* et les différentes comparaisons ne sont donc pas parallélisées.

Du 15 février au 04 mars, un bug du routeur de RENATER nous empêchait de nous connecter au site de Nancy et de récupérer notre travail par `scp`. Cela nous a posé un gros problème car nous n'avions pas eu le temps de copier le script sur les autres sites et nous avons donc commencer le rapport en attendant la résulution du bug.

Nous avons changé trois fois de format de sortie de l'outil `oarnodes` pour récupérer les informations de l'OAR Database : En effet, la sortie *XML* n'était pas véritablement homogène au niveau national : certaines informations pouvaient être en attribut sur certains sites en contenu sur d'autres. Lorsque, sur les conseils de M.Nussbaum, nous avons essayé de récupérer les informations en format *JSON* mais le module *Perl* correspondant n'était pas présent sur le site de Nancy. (Bug soumis aux administrateurs compétents et résolu). Nous nous sommes donc rabattu sur la sortie *YAML* pour ne pas avoir à attendre la résolution du problème.

À Grenoble, le module *Perl* `XML::Simple` n'était pas disponible, nous avons alors dû l'installer dans le répertoire de notre script. Par précaution, nous avons fait de même pour les autres modules.

Chapitre 4

Benchmarks

S'il existe une possibilité pour qu'une expérience échoue, elle échouera.

1 Préambule

L'objectif de ces tests consiste à mesurer les débits et latences constatés entre chacun des nœuds d'un cluster. Ainsi, nous mettrons en exergue l'infrastructure du réseau auquel est lié le cluster en constatant les goulots d'étranglements liés aux commutateurs, par le biais des tests de bisssection. D'une façon plus générale, ils permettront de détecter les nœuds qui ne peuvent pas communiquer entre eux.

2 MPI

Message Passing Interface (MPI) est une norme accompagnée de bibliothèques prévue initialement pour le *C/C++* et le *Fortran* (quelques portages vers d'autres langages comme *Java*, *Python* ou *OCaml* ayant été implémentés depuis). Comme son nom l'indique, son rôle se cantonne à faire transiter des messages. Il est donc naturellement utilisé pour faire communiquer des machines entre elles au sein d'un cluster, tels que ceux que propose le projet Grid5000. La spécificité de MPI par rapport aux autres bibliothèques de même rôle est d'être portable (il est prévu pour la plupart des systèmes d'exploitation), et d'être optimisé pour beaucoup de matériels. Avec ce dernier point, MPI est donc parfaitement adapté pour les réseaux rapides tels que Myrinet ou Infiniband que Grid5000 met à disposition.

Comme ses langages de prédilections le laissent supposer, la norme est ancienne (1993), et sa dernière version - MPI 2 - date de 1997. C'est cette version-ci que nous utiliserons. Le langage choisi pour notre programme, lui, sera le *C* (un langage puissant et largement utilisé, pour lequel nous avions peu d'expérience et que nous avons voulu mieux maîtriser).

Historique

– **Version 1.0** : En juin 1994, le forum MPI, aboutit à la définition d'un ensemble de sous-programmes concernant la bibliothèque d'échange de messages MPI.

- **Version 1.1** : Juin 1995, cette version n'apporte pas de changements majeurs par rapport à la version initiale.
- **Version 1.2** : Apparue en 1997 : changements mineurs, en rapport avec la dénomination de certains programmes.
- **Version 1.3** : Septembre 2008 : clarifications sur la version 1.2 et 2.1.
- **Version 2.0** : Juillet 1997, cette version a apporté des compléments non implémentés (volontairement) dans la version 1.0 (gestion dynamique des processus, entrées/-sorties parallèles, copies de mémoire à mémoire, etc.).
- **Version 2.1** : Juin 2008 : clarifications de la version 2.0 mais aucun changements.
- **Version 2.2** : 2009 : corrections pour "coller" au standard de la 2.1.
- **Version 3.0** : 2010, cette version devrait apporter des tolérances aux fautes, des communications collectives non-bloquantes, etc.

http://meetings.mpi-forum.org/MPI_3.0_main_page.php

2.1 Implémentations

La norme MPI est parfaitement portable mais ça n'est malheureusement pas le cas de ses implémentations. En effet, même s'il est possible de compiler et d'exécuter un programme utilisant MPI sur la plupart des plate-formes, l'exécution du programme dépendra de l'implémentation utilisée.

Il existe trois principales implémentations de MPI2 : OpenMPI, LAM et MPICH2. LAM est une ancienne implémentation qui n'évolue plus actuellement et qui a laissé officiellement place à OpenMPI. MPICH2, quant à lui est une autre branche indépendante. Ces deux solutions sont des logiciels libres et open-source, dont l'avantage au niveau performances semblerait revenir au second. Sur Grid5000, on trouve ces deux implémentations, ainsi parfois que LAM. Beaucoup de clusters en proposent plusieurs à la fois. Un programme *C* qui utilise MPI se compile avec le compilateur de l'implémentation choisie, et s'exécute par le biais d'une commande de gestion qui permet de sélectionner les nœuds de la réservation qui seront concernés par cette exécution.

A chaque nœud de l'exécution du programme est attribué un rang, de zéro à *(nombre de nœuds)-1*. Chaque nœud, par l'intermédiaire des commandes MPI, peut consulter son numéro de rang, ainsi que le nombre de machines concernées par l'exécution du programme.

3 Les solutions de tests existantes

3.1 OSU Micro-Benchmarks

Les benchmarks OSU Micro-Benchmarks (OMB) sont disponibles au téléchargement sur le site de l'*Ohio State University*[1]. Les tests réalisés sont très complets (latence, bande passante, etc.).

- L'exécution des tests se fait par paliers (taille du message de plus en plus grosse).
- Ces tests ne fonctionnent qu'avec deux processus, impossible donc de faire des matrices et des *bissections*.

1. http://mvapich.cse.ohio-state.edu/benchmarks/OMB-3.1.1.tgz

– Certains des tests sont compatibles MPI1 et d'autres MPI2 (MVAPICH2).

Latence

Les tests de latence utilisent spécifiquement la méthode ping-pong, et les versions bloquantes de MPI (`MPI_Send` et `MPI_Recv`). L'envoyeur envoie un message au récepteur et attend sa réponse. Le récepteur reçoit alors le message de l'expéditeur et envoie alors une réponse de même taille que le message précédemment reçu. On calcule le temps mis.

Comme toujours, plusieurs itérations du test sont effectuées dans le but de prendre la moyenne.

Lancement d'un test :

```
mpirun -np 2 --mca plm_rsh_agent oarsh -machinefile $OAR_NODEFILE ./
    osu_latency
```

La commande précédente nous retourne les résultats suivants :

```
# OSU \gls{MPI} Latency Test v3.1.1
# Size            Latency (us)
0                         0.85
64                        1.02
2048                      4.08
131072                  154.08
4194304                4906.56
```

Débit

Les tests de bande passante sont réalisés par l'envoi d'un message à taille fixe au récepteur. Une fois que le récepteur a reçu le message, il renvoie sa réponse sous forme d'un *Ack* (*Acknowlege*). Le processus est répété plusieurs fois, pour avoir une moyenne, et la bande passante est calculée en fonction du temps écoulé (de l'envoi du premier message, jusqu'à la fin de l'envoi du dernier message du récepteur) et le nombre d'octets envoyés.

Les fonctions MPI utilisées sont les fonctions non bloquantes d'envoi et de réception (`MPI_Isend` et `MPI_Irecv`).

L'objectif de ce test est donc de visualiser la bande passante maximale soutenue par le réseau rapide.

Lancement d'un test :

```
mpirun -np 2 --mca plm_rsh_agent oarsh -machinefile $OAR_NODEFILE ./osu_bw
```

Retour de la commande, avec la taille du mot envoyé et le débit correspondant :

```
# OSU \gls{MPI} Bandwidth Test v3.1.1
# Size        Bandwidth (MB/s)
1                         1.96
[...]
32                       52.34
64                      103.86
1048576                1040.28
4194304                1042.02
```

Particularités :

– Requiert deux processus maximum.
– Tests de latence et débits indépendants.

Les tests Ohio State University (OSU), sont très complets et pratiques, ils permettent de tester rapidement son infrastructure réseau, en utilisant MPI. Cependant ils ne peuvent faire intervenir que deux machines.

3.2 NetPipe

Network Protocol Independent Performance Evaluator (NetPIPE) est un outil permettant une visualisation rapide des performances du réseau. Il se base sur la méthode ping-pong, avec des messages de taille croissante, entre deux processus. Les tests sont répétés plusieurs fois dans le but de constituer une moyenne.

Lancement d'un test :

```
mpirun -np 2 --mca plm_rsh_agent oarsh -machinefile $OAR_NODEFILE ./NPmi
```

Résultats :

```
0: gdx-89
1: gdx-89
Now starting the main loop
  0:       1 bytes  86569 times -->      8.31 Mbps in       0.92 usec
[...]
102:  786435 bytes     75 times -->   6836.34 Mbps in     877.67 usec
[...]
123: 8388611 bytes      5 times -->   6513.34 Mbps in    9825.99 usec
```

Particularités :
– Tests de débit et latence en même temps
– Incrémentation de la taille des messages par palier
– Requiert deux processus maximum
– Ne permet pas de faire de bissections ou matrices.

3.3 NWS

Network Weather Service (NWS) est une méthode de calcul basée sur la lecture des conditions du réseau à un instant `t`. Puis des méthodes mathématiques permettent de prévoir la fluctuation. C'est pour cette raison que cette méthode porte ce nom, car comme pour une prévision météorologique, on prends un cliché instantané puis on en détermine les possibles évolutions.

C'est une fraction de cette méthode que nous utiliserons pour notre programme.

3.4 Tests Alternatifs

Différents autres outils de base peuvent être utilisés, dans le but de tester les performances.
Cependant, leur utilisation est souvent plus complexe.
– Les commandes de la carte (`mx_info`, `ibv_devinfo`, `ib_read_lat`, etc.)
– La suite Kanif (`Kash`, `Kaput`, etc.)
– `Perfquery`
– `Perftests`

3.5 Conclusion

Malgré les nombreuses solutions testées, nous n'avons pas trouvé de solution existante convaincante, permettant de mettre en avant la faiblesse d'un nœud spécifique dans un cluster. De plus la quasi-majorité des solutions ne mettait en œuvre que deux nœuds, impossible donc de faire un test de débit/latence sur tout un cluster, ou même de faire une bissection ainsi qu'une matrice.

C'est pour cela que nous avons été amené à développer notre propre programme de test.

4 Programme principal

4.1 Objectif

L'objectif du programme est de mesurer la latence et le débit entre chaque paire de nœuds possible. Si une réservation concerne dix nœuds, il y a aura donc dix fois dix tests de débit/latence à faire. Le programme doit présenter les résultats sous forme d'une matrice, et avoir la possibilité d'exporter ces résultats sous forme de fichier *YAML*.

Un mode bissection est également à prévoir : il s'agit de couper en deux la liste de tous les nœuds pour créer des paires. Une fois ces paires formées, tous les tests doivent s'exécuter en même temps afin d'éventuellement saturer le commutateur réseau. C'est ensuite le débit total de tous ces échanges qui sera utilisé pour faire l'interprétation.

4.2 Les tests

Pour la latence, nous considérerons qu'il s'agit du temps mis par un message vide pour transiter d'un nœud à l'autre. Elle sera donc obtenue en calculant le temps mis depuis l'envoi du message au nœud distant jusqu'à la réception de son acquittement. Puisqu'il s'agit de ne calculer que le temps de transition du message, ce temps doit être divisé par deux. La latence se mesure en microsecondes.

Pour ce qui est du débit, nous considérerons qu'il s'agit du temps mis par un octet pour transiter d'un nœud à l'autre. Pour le calculer plus précisément et éliminer les imperfections du réseau, il est nécessaire d'envoyer des messages de plusieurs octets (nous considérons qu'il est nécessaire d'avoir plus de soixante-quatre kilooctets pour avoir des résultats pertinents) pour ensuite diviser le temps constaté. Elle sera donc obtenue en calculant le temps mis depuis l'envoi du message jusqu'à la réponse - vide - du nœud distant. La latence calculée auparavant sera retirée deux fois (aller et retour) afin de n'obtenir que le temps consacré pour faire transiter le message, sans tenir compte de l'impureté du réseau. Le débit se mesure en méga-octets par seconde.

Cette façon de calculer ces deux valeurs relève de l'approche NWS [2].

2. http://nws.cs.ucsb.edu

4.3 L'algorithme

Principe

Notre programme exploite au mieux les possibilités offertes par la norme MPI2. Ainsi, nous avons créé de nouvelles structures MPI à partir de structures C que nous utilisons dans notre programme. En utilisant les types créés, nous pouvons passer ces structures d'un nœud à l'autre. Trois structures sont au rendez-vous : `Bench`, `YourTest` et `MyResult`. `Bench` est une structure qui contient un numéro d'envoyeur (correspondant à un rang), un numéro de receveur (un autre rang) ainsi que deux valeurs correspondant au débit et à la latence constatés lors du test consistant à aller de l'envoyeur vers le receveur. `YourTest`, elle, contient un attribut `role` et un numéro de rang. Le rôle peut correspondre soit à *envoyeur*, *receveur* ou *désactivé*. Nous verrons ce dernier dans la suite de l'explication du programme, et les deux autres sont maintenant explicites. Enfin, `MyResult` contient un attribut de type `Bench` et une chaîne de caractères correspondant à un nom de domaine.

Le programme se divise en deux contextes principaux : le nœud de rang zéro, et les autres. En effet, le nœud qui se verra attribuer ce rang spécial aura pour charge de centraliser les résultats, mais aussi de créer les différents tests, les attribuer aux nœuds, et donner le départ des tests (de façon globale si c'est une bissection, pair à pair sinon). Ce nœud ne participera donc pas aux tests, et ne se retrouvera pas dans les résultats. Si on veut que la machine de ce rang-ci participe, il faut la répéter deux fois en début du fichiers des nœuds participants. MPI est multi-processeurs, il prendra donc le premier processeur du nœud de rang zéro (le premier dans la liste) pour gérer la batterie de tests, et le second pour représenter la machine au sein des résultats.

Le contexte du nœud zéro, que nous appellerons dorénavant maître, commence son exécution en différenciant une exécution pour un mode bissection (option *-b* du programme) ou non. Les autres nœuds, eux, se mettent à l'écoute du maître. Selon que le mode bissection est actif ou non, ils écouteront de façon collective (point qui sera abordé par la suite) ou individuellement. Écouter signifie se mettre en attente d'un envoi du maître, et bloquer le programme jusqu'à ce que celui-ci ait daigné leur envoyer un message.

Les sources du programmes sont disponibles en annexe 5 et 6 pages 60 et 76.

Le mode matrice

Pour ce mode, chacun des nœuds qui n'est pas maître commence par se mettre en écoute, individuellement, sur celui-ci. Ceci signifie que leur exécution ne continuera que lorsque celui-ci leur aura explicitement envoyé un message. Ce qu'ils attendent tous, c'est un test de type `YourTest`. Une fois qu'ils auront ce test, ils pourront consulter leur rôle et savoir quelle attitude adopter dans la suite de leur exécution.

Le maître, lui, parcourt les rangs des nœuds un par un. Pour chacun de ces nœuds il se livrera au même rituel : il commence par invoquer la préparation des tests, en fonction du rang sur lequel il s'est arrêté. La préparation consiste à parcourir tous les rangs qui ne sont pas le rang donné. Pour chacun, un test est créé : ils seront tous receveurs, et leur compagnon de jeu sera le rang du nœud donné. Tous ces tests leur sont ensuite envoyés individuellement. Chacun était à l'écoute de son test, et se débloque donc à cette arrivée. Comme ils sont tous de même rôle, ils choisissent tous la même action : se mettre à écouter le rang donné. Ce dernier est le seul à ne pas avoir de rôle dans cette partie, nous lui donnons donc naturellement le rôle d'envoyeur. Une fois qu'il a réceptionné son rôle, il sait exactement ce qu'il doit faire en fonction. Il commencera par déclencher un chronomètre, puis enverra un message vide au premier receveur, et se mettra en écoute de celui-ci. Le receveur s'empressera de répondre et l'envoyeur pourra arrêter son chronomètre. Un calcul de latence est alors déduit du temps mis entre les deux mesures de temps. Dans la foulée le second test se déroule de la même façon, mais avec un message bien plus gros (selon la valeur de l'option *-s* passée au programme, et par défaut un mégaoctet). Le receveur renverra sa réponse - vide - et l'envoyeur pourra valider ce nouveau chronomètre. En fonction du temps mis par ce second test et de la latence calculée précédemment, on déduit le débit. Ces deux tests seront répétés un certain nombre de fois (selon l'option *-p*, et par défaut dix fois). Un débit ainsi qu'une latence seront déduits de la moyenne de ceux-ci. En fonctionnant ainsi, nous éliminons en partie les défauts du réseau qui peuvent intervenir, et qui ne pourrait pas rendre un seul test représentatif.

Ces résultats sont naturellement stockés dans une structure de type `MyResult`. En plus de contenir les informations concernant les parties du tests ainsi que les résultats, un nom de domaine est fourni. Il s'agit du nom de domaine de l'envoyeur, qui communiquera cette structure au maître (qui s'est mis en écoute d'une donnée de ce type de la part de l'envoyeur actuel, juste après avoir donné le rôle). Le maître reçoit ce résultat, le stocke, et reformule un test à l'envoyeur pour produire des résultats avec le second receveur. Le premier receveur, lui, s'est remis en écoute du maître. Dans ce mode, tous les nœuds se remettent en écoute du maître après avoir fini jusqu'à ne plus avoir de rôle à jouer (si *nb* représente le nombre de nœuds concernés par l'exécution du programme, chaque nœud sera *nb-2* fois envoyeur et autant de fois receveur ; les deux nœuds retirés chaque fois étant le nœud de rang zéro qui fait office de maître ainsi que lui-même).

Une fois que chaque nœud a réalisé un test avec chacun des autres nœuds et qu'il a remonté ses résultats au maître, le programme se fini pour eux, en fermant la connexion MPI et en quittant le programme. Le maître se retrouve seul pour rendre compte des résultats. Il les organise et les affiche sous forme de matrice sur la sortie standard. Il fournit en plus des statistiques telles que la paire de nœud qui a enregistré le plus bas et le plus haut débit, et le même type de résultats pour la latence. Si l'utilisateur a demandé une sortie *YAML*, celle est effectuée en plus, dans le fichier donné en paramètre (option *-o*).

Le mode bissection

Si l'utilisateur a demandé le mode bissection (option *-b*), la philosophie des tests diffère. Il s'agit en effet de ne plus distribuer les rôles, de récupérer les résultats et surtout de faire les tests consécutivement, mais d'exécuter toutes ces tâches parallèlement, en s'assurant que tous démarrent en même temps. L'objectif est en effet de saturer le com-

mutateur réseau et de constater quel est le débit total lorsque toute une moitié de cluster échange une information avec l'autre moitié. Avec ce type de test, nous devrions mettre en évidence l'emplacement des commutateurs, puisqu'ils devraient agir en goulot d'étranglement, ce qui se reflétera sur les débits constatés entre certains nœuds.

A l'exécution du programme, tous les nœuds qui ne sont pas le maître se mettent à l'écoute d'un test de celui-ci. Mais d'une façon différente du mode matrice, puisque nous exploitons ici l'autre force MPI : les fonctions collectives. Ainsi, chaque nœud se met à appeler précisément la même fonction qui stipule qu'ils recevront un message de type `YourTest` du maître. Chacun de ces nœuds ne sera débloqué que lorsque le maître lui-même aura invoqué cette même fonction, pour envoyer ses tests.

Le maître, lui, commence comme pour le mode matrice : il s'attelle à préparer les tests. Cette préparation consiste avant tout à créer des couples. Pour faire une bonne bissection, il faut d'abord couper la liste des nœuds en deux parties égales (en prenant soin d'écarter le nœud maître ainsi que le petit dernier si jamais le nombre était impair). Pour prendre des nœuds deux à deux et créer des couples d'envoyeur/receveur, il existe deux écoles : l'école de l'aléatoire et l'école de *la moitié+1*. L'une ou l'autre de ces écoles est utilisée selon que l'option *-rb* (pour *Random Bisection*) ait été passée. Ainsi, dans le mode aléatoire, tous les nœuds n'ayant pas de rôle seront rassemblés dans un grand panier. Puis, tour à tour, deux seront tirés au sort et se verront respectivement s'attribuer le rôle d'envoyeur ou de receveur de l'autre, jusqu'à ce que tous les nœuds aient été intégrés dans un test. Dans le mode *moitié+1*, le premier nœud de la liste sera envoyeur, avec le premier nœud de la seconde moitié de la liste, plus un, qui sera receveur. Ainsi de suite, jusqu'à ce que le dernier nœud de la première moitié ait été intégré à un test.

Vient alors le temps de distribuer ces rôles : le maître se décide enfin à appeler la fonction collective sur laquelle tous les autres nœuds sont bloqués, impatients de recevoir leurs tests, comme un enfant sous un sapin de Noël qui regarderait inlassablement le conduit de la cheminée. Une fois que chacun d'eux a reçu son rôle, chacun se met en position de combat : la même que si ils étaient en mode matrice, sauf qu'il se mette d'abord à réécouter le maître. D'une façon différente cette fois-ci : à l'aide d'une seconde fonction collective correspondante à un broadcast. Tout le monde recevra donc en même temps le même message, et ce sera un message vide.

L'intérêt de ce message qui bloque le début des tests est de s'assurer que chaque test commencera exactement au même instant, et qu'il n'y aura pas un décalage dû au temps pour chacun de recevoir son rôle (puisque tous les nœuds ne sont pas accessibles à la même vitesse, ce qui est justement ce que nous cherchons à prouver). Le message vide est envoyé, les envoyeurs envoient et les receveurs reçoivent. Les tests se déroulent de la même façon que dans le mode matrice à une exception près : chaque test devant être refait un certains nombre de fois pour prendre la moyenne de tous, il ne s'agit pas que les paires de nœuds les plus rapides terminent tous leurs tests avant les autres. Si une telle chose se produisait, les goulots d'étranglement n'étrangleraient plus, et les derniers nœuds communiqueraient plus rapidement sur leurs derniers tests, faussant ainsi leurs propres moyennes de résultats. Pour pallier ce problème, chacun des nœuds se remet en écoute de la fonction de broadcast du maître avant de relancer un test. Ainsi, les plus rapides attendent toujours les plus lents avant de recommencer leurs tests.

Une fois que chacun a fini sa série de tests avec son partenaire, chacun appelle la dernière fonction collective, inverse exact de la première utilisée. C'est à dire que ça n'est plus le maître qui envoie simultanément tous les tests personnalisés aux nœuds, mais les nœuds qui envoient chacun leur résultat au maître. Celui-ci les reçoit tous, les stocke, et les gère de la même façon pour le mode matrice.

4.4 Saturation des commutateurs

Une utilisation pratique du mode bissection consiste à réaliser une série de tests consécutifs, en faisant varier le nombre de nœuds dans la partie. Ainsi, le programme sera d'abord exécuté avec trois nœuds (option *-np* de `mpirun`). De cette bissection, le débit total sera récupéré (addition des débits constatés entre chaque paire de nœuds). Le programme sera réexécuté en ajoutant quelques nœuds et ainsi de suite jusqu'à tous les utiliser. De ces expériences ressortent des relations entre le nombre de nœuds impliqués dans une bissection et le débit total constaté.

Nous pouvons ainsi constater le seuil de saturation du réseau lorsque les commutateurs ne tiennent plus suffisamment la charge pour accueillir encore plus de débit et agissent donc en goulot d'étranglement. Grâce à l'option *-g* du programme, seul le nombre de nœuds en fonction du débit total de la bissection sont affichés. Ainsi, il est possible de compléter au fur et à mesure un fichier qui bénéficiera d'une syntaxe compatible avec le programme `gnuplot` qui permettra de tracer des graphiques de débit. Un script `bash` a été écrit pour automatiser cette série d'expériences et créer automatiquement le fichier `gnuplot`. Sa seule option est un pas correspondant au nombre de machines à ajouter à chaque nouvelle bissection.

La source du script est disponible en annexe 7 page 77.

4.5 Matrice d'ornement

Enfin, un script *Ruby* (langage moderne et très bien interfacé avec le *YAML*) a été écrit pour exporter la matrice des résultats sur un site internet. Ainsi, à partir d'un fichier *YAML* généré par le programme, le script crée un fichier *HTML* de la matrice, plus esthétique et plus facilement consultable. De plus, les débits et latences constatés sont colorés en fonction de leur position dans le classement des performances : le débit et la latence les plus bas sont marqués sur fond rouge, et les plus hauts sur fond vert.

De façon intermédiaire, les débits et latences faisant partie du premier quartile des résultats sont marqués en vert, et ceux faisant partie du troisième quartile sont en rouge. Un quartile est une valeur statistique mathématique qui se calcule en classant tous les résultats, pour en calculant pour chaque « l'effectif cumulé croissant »(*ecc*) qui leur est associé (addition de tous les résultats qui les précède). Lorsque l'*ecc* d'une valeur est inférieure à un quatrième du total des résultats, alors celle-ci fait partie du premier quartile. Lorsqu'elle fait partie du quatrième quart, il s'agit d'une valeur du dernier quartile. Ce code couleur permet de repérer instantanément les nœuds qui font défaut et ceux qui sont performants. Ces derniers étant souvent proches les uns des autres ou font partie d'un commutateur peu chargé.

-i, –yaml	Fichier *YAML* d'entrée.
-o, –html	Fichier HTML de sortie.
-h	Une aide de ce type.

La source du script est disponible en annexe 9 page 78.

4.6 Déploiements

L'intérêt

Lors de l'utilisation d'un cluster, on peut être amené à utiliser des logiciels qui ne sont pas installés sur les environnements de production. L'intérêt des déploiements est alors multiple.

Dans un premier temps, il permet de de configurer chaque nœud à sa guise, installer les logiciels que l'on veut, et ainsi ne pas « polluer »l'environnement de production avec des logiciels dont nous seuls avons l'utilité. Il permet également de changer la configuration même du système (mise à jour du noyau, déploiement avec des distributions exotiques, etc.).

Dans un second temps le déploiement permet de sauvegarder et d'exporter l'environnement ainsi modifié. Puisque le déploiement se fait à partir d'une archive, l'archive peut être portée sur différents sites, et ainsi être réutilisée ultérieurement.

Dans un dernier temps, le déploiement permet de lisser l'exécution de nos programmes, principalement d'un site à l'autre puisque l'hétérogénéité des environnement de production empêche le fonctionnement normal. L'utilisation d'un même environnement permet donc de lisser ces problèmes.

L'utilisation de MPI dans les environnements de développement est assujettie aux problèmes. En effet, selon les clusters, on rencontre différentes implémentations de MPI, qui ne supporteront pas les même options. De plus, pour les clusters concernés, certains ne supportent pas par défaut leurs propres réseaux rapides. Enfin, beaucoup d'environnements soulèvent des problèmes de connexions entre les nœuds. Sur certains clusters, MPI devra contacter les autres nœuds via `ssh`, d'autres via `oarsh`, ou encore via `rsh`. Certains nécessitent l'utilisation d'une clé *SSH* sans *passphrase* ou un `user-agent` pour se connecter sans demander de mot de passe (qui serait impossible à renseigner).

L'intérêt de déployer son propre environnement est de faire face à tous ces problèmes en recréant un système qui supportera parfaitement les deux types de réseaux rapides et qui proposera une seule implémentation de notre choix de MPI (qui fonctionnera avec les réseaux rapides). Pour les interconnexions, une liaison *SSH* par clé *SSH* sans *passphrase* sera largement suffisante.

Support de Infiniband

Le support d'Infinband sur un environnement fraîchement installé est relativement facile à mettre en place. Son aspect libre y étant pour beaucoup !

En effet les cartes Infiniband Mellanox installées sur les différents nœuds de Grid5000 sont déjà reconnues par le noyau Linux. L'étape la plus compliquée consiste alors à lister les modules utiles, pour ce que l'on veux faire (support de IP sur Infiniband) et de les activer (`modprobe <module>`), ou de les inscrire directement dans le fichier */etc/modules*. Ainsi, ceux-ci seront directement chargés au prochain déploiement.

Nous sommes donc partis d'un système *lenny-x64-base*, que nous avons mis à jour afin de bénéficier d'un noyau plus récent que le 2.6.26. Avec la mise à jour, nous avons installés les drivers propriétaires *(sic)*, et OpenMPI, une implémentation libre de MPI.

Certaines modifications ont été apportées, comme l'ajout d'utilisateurs, la mise en place de clés et la cohabitation entre Infiniband et Myrinet.

Un tutoriel complet créé par nos soins est disponible en annexe 10 (page 82).

Support de Myrinet

Le support de Myrinet sur l'environnement personnalisé n'aura pas été tout à fait aisé.

Un tutoriel complet créé par nos soins est disponible en annexe 11 (page 87).

Système de départ Pour partir d'un bon pied, nous avons utilisé un des environnements proposés dans la base de données des environnements de OAR. Comme le seul vraiment supporté est la version lenny de Debian, c'est celle-ci que nous mettons en œuvre. Une fois déployée, la première étape consiste à la mettre à jour : nous passons le système en testing. Un problème au niveau de `udev`, récurrent à ce moment là, intervient. Il faut redémarrer le système en plein milieu de l'installation pour la poursuivre.

Drivers Myrinet Pour que les drivers Myrinet fonctionnent, il faut qu'ils soient compilés avec précisément le même compilateur que le noyau du système. La seule façon de s'en assurer est donc de recompiler le noyau, en en profitant pour installer une version récente (2.6.32). Pour bien faire les choses, nous créons un paquet Debian de ce nouveau noyau.

Vient la récupération des drivers Myrinet : lorsque nous tentons de les récupérer, nous découvrons que la société Myricom impose l'envoi d'un email pour obtenir le mot de passe permettant le téléchargement. Une fois cette contrainte exécutée, nous recevons

une réponse nous demandant de fournir un numéro de client [3]. Ce genre de chose est laborieuse à obtenir, notre tuteur réussi finalement à retrouver un email contenant le mot de passe, nous permettant toujours de télécharger les sources des drivers. Par la suite, nous tenterons aussi de récupérer une version de MPICH2 (une implémentation de MPI) qui supporte le Myrinet, qui se trouve sur le même site Internet. Là encore, nous serons confronté au même problème, sans solution cette fois-ci (sauf celle d'utiliser une autre implémentation de MPI à laquelle nous intégrerons ce support). J'en profite donc pour mettre l'accent sur les désagréments des logiciels propriétaires, soumis à des contraintes stupides, et surtout consommatrices de temps. Le support d'Infiniband, l'autre réseau rapide, est libre, et donc supporté par défaut dans les noyaux Linux récents.

Une fois les drivers finalement récupérés et compilés, un second paquet Debian a été créé. Pour lancer la création de l'interface de Myrinet au démarrage de la machine (et donc à la fin du déploiement), nous avons écrit un service qui lance et arrête l'ensemble des commandes qui activent le support de Myrinet.

Enfin, nous avons fait le choix de OpenMPI pour les support de MPI sur nos environnements. Ce choix par rapport à MPICH2 s'est fait parce que celui-ci ne supporte pas Infiniband par défaut et parce que la version Myrinet ne nous est pas accessible. Puisque Myrinet est propriétaire, le paquet Debian ne le supporte pas. Nous l'avons donc recompilé et créé par la même occasion un paquet Debian fonctionnel.

Une fois un utilisateur créé, des clés *SSH* bien placées et avoir vérifié que tout fonctionne bien, nous avons enregistré ce nouvel environnement, prêt à faire communiquer notre programme MPI sans problème et en utilisant éventuellement les réseaux rapides.

Problèmes Malheureusement, tout n'est pas si parfait. En effet, comme nous avons déjà eu l'occasion de nous en rendre compte, l'universalité des clusters est une illusion. Ainsi l'image que nous avons créé à Orsay ne fonctionne pas dans certaines villes (Rennes, par exemple). Certains problèmes ont été résolus par l'installation de *firmwares* propriétaires *(sic)*. D'autres restent toujours obscurs. Nous avons en effet dialogué avec les utilisateurs de la liste email à laquelle nous nous sommes tous abonnés, et à ce jour nous ne savons toujours pas pourquoi l'image refuse de se déployer sur ces villes.

Dans l'avenir, nous espérons que tous les environnements de développement proposent des implémentations de MPI fonctionnelles, avec des interconnexions faciles, et un support natif de leurs propres réseaux rapides. Durant la période de notre projet tuteuré, des avancements ont déjà été effectués dans ce sens sur plusieurs sites.

4.7 Résultats

Utilisation du programme

Le programme s'utilise à travers la commande `mpirun`, en indiquant un fichier de nœuds dédoublonné. Éventuellement répéter le premier nœud (qui sert de maître) pour

3. « *Please send a serial number from one component - the 6-digit number prefixed by "SN" on the white label - so that we can verify your license* »

le faire apparaître dans les résultats.

-s <n>K	Taille des messages utilisés pour les tests de débit en octets (avec les suffixes K, M ou G). Taille minimum de 64K, par défaut 1M.
-p <n>	Précision des tests (nombre de fois que chaque test sera répété pour prendre la moyenne de tous). Par défaut 10.
-b	Mode bissection (premier nœud de la première moitié avec le premier de la seconde, et ainsi de suite).
-rb, -r	Mode bissection, avec des formations de paires de nœuds aléatoires.
-bg, -g	Sortie pour un fichier de données `gnuplot`.
-o <file>	Sortie *YAML*.
-h	Une aide de ce type.

Exemples de sortie

Matrice de débits/latences avec cinq nœuds concernés :

	To gdx-212	To gdx-213	To gdx-214	To gdx-215
From gdx-212		14,400 us 635,740 Mo/s	15,128 us 644,675 Mo/s	14,949 us 640,825 Mo/s
From gdx-213	7,844 us 671,236 Mo/s		12,708 us 669,531 Mo/s	12,767 us 665,154 Mo/s
From gdx-214	7,665 us 668,970 Mo/s	7,403 us 669,591 Mo/s		13,196 us 662,985 Mo/s
From gdx-215	7,200 us 672,025 Mo/s	7,010 us 673,011 Mo/s	7,057 us 670,242 Mo/s	

```
Latency :
Max : 15,128 us        From gdx-212 to gdx-214
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 gdx-215 to gdx-213
Min : 635,740 Mo/s     From gdx-212 to gdx-213
Sum : 7943,985 Mo/s
Avg : 661,999 Mo/s
```

Bissection, avec six nœuds (option *-b*) :

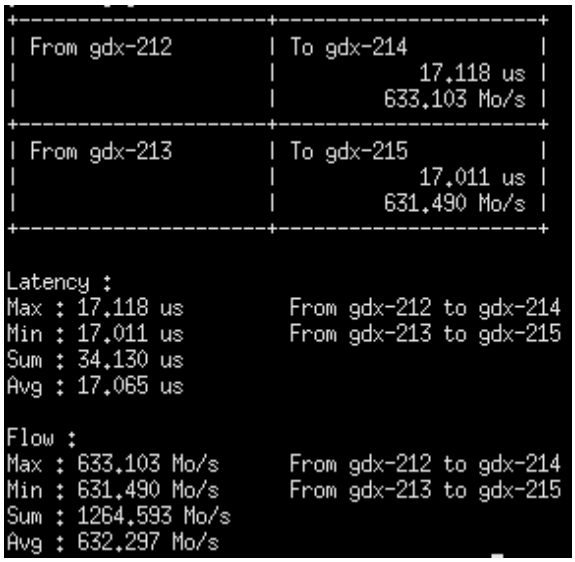
+--------------------+--------------------+
From gdx-212	To gdx-214
	17.118 us
	633.103 Mo/s
+--------------------+--------------------+
From gdx-213	To gdx-215
	17.011 us
	631.490 Mo/s
+--------------------+--------------------+
Latency :
Max : 17.118 us   From gdx-212 to gdx-214
Min : 17.011 us   From 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 gdx-213 to gdx-215
Sum : 1264.593 Mo/s
Avg : 632.297 Mo/s

Sortie *YAML* (option *-o*) :

```
gdx-212 :
  gdx-213 :
    latency : 14.067
    flow : 633.161
  gdx-214 :
    latency : 14.400
    flow : 646.889
  gdx-215 :
    latency : 14.949
    flow : 633.000
  gdx-216 :
    latency : 15.390
    flow : 641.042
gdx-213 :
  gdx-212 :
    latency : 7.343
    flow : 668.495
  gdx-214 :
    latency : 11.909
    flow : 677.445
  gdx-215 :
    latency : 11.206
    flow : 663.127
  gdx-216 :
    latency : 12.112
    flow : 671.858
gdx-214 :
  gdx-212 :
    latency : 7.880
    flow : 670.927
```

Tests consécutifs de bissections avec l'option *-g* et le script *bash*, pour des débits sur Ethernet (graphique avec le script `gnuplot` disponible en annexe 8) :

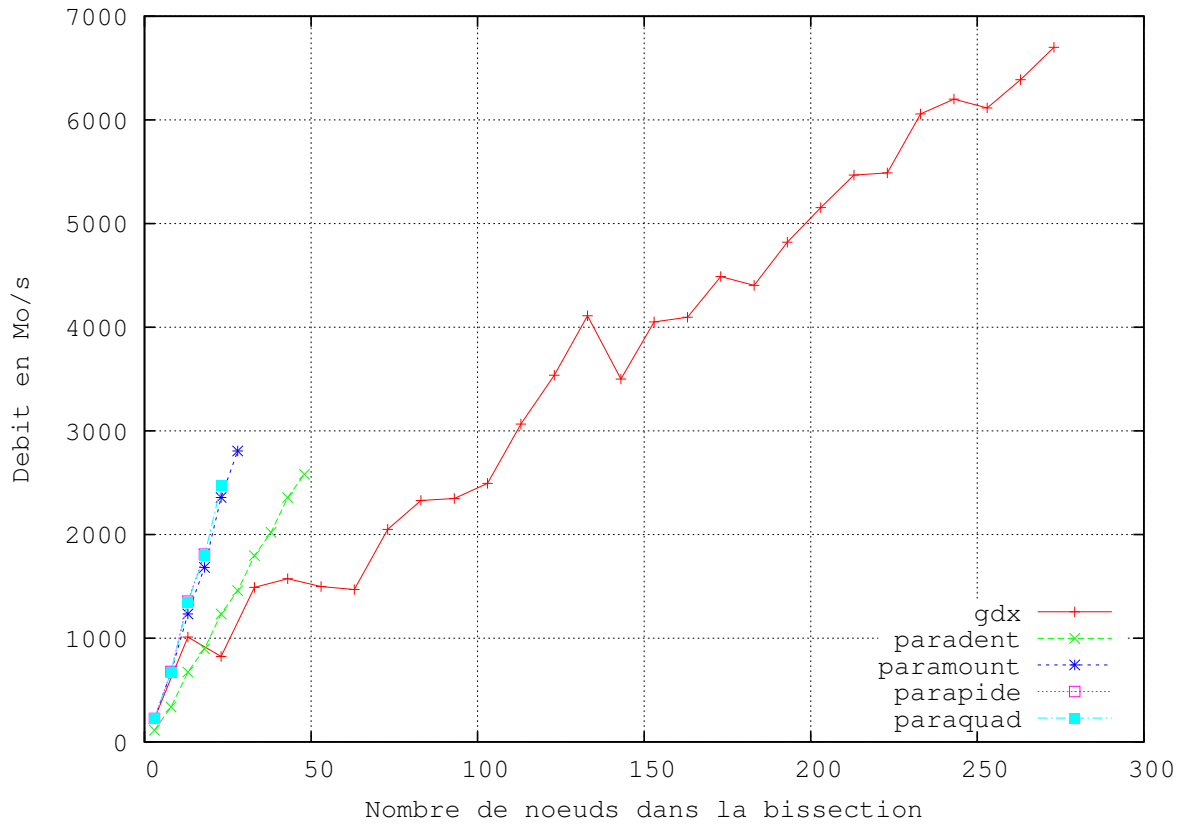

Sortie HTML de la matrice avec le script *ruby* :

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**

4.8 Problèmes rencontrés

MPI

La majorité des problèmes rencontrés avec MPI, relève de l'hétérogénéité des différents sites, ainsi un programme ne se lancera pas de la même manière sur les environnements de production, selon que l'on soit à Rennes, à Nancy, ou autre part.

Erreur concernant un réseau rapide Myrinet alors que le cluster (netgdx sur Orsay, ainsi que certains clusters de Rennes) n'en propose pas : *warning :regcache incompatible with malloc.*
Il semblerait que le problème vienne de la compilation de OpenMPI (compilation pour utiliser Myrinet, alors que c'est souvent Infiniband qui est supporté).

Impossible de faire communiquer les programmes entre eux à Lyon, une invitation de mot de passe impossible à saisir bloque les accès.

```
$ mpirun -np 5 --mca plm_rsh_agent oarsh -machinefile $OAR_NODEFILE ./
    latency_flow_tests
Warning: Command line arguments for program should be given
after the program name.  Assuming that plm_rsh_agent is a
command line argument for the program.
Warning: Command line arguments for program should be given
after the program name.  Assuming that oarsh is a
command line argument for the program.
```

```
Unrecognized argument --mca ignored.
The authenticity of host 'capricorne-6.lyon.grid5000.fr (10.69.0.6)' can't
    be established.
RSA key fingerprint is d5:35:1a:e6:4b:12:25:c3:3d:2e:59:03:5c:fb:c2:58.
Are you sure you want to continue connecting (yes/no)? yes
Warning: Permanently added 'capricorne-6.lyon.grid5000.fr,10.69.0.6' (RSA)
    to the list of known hosts.
Password:
```

Toujours sur Lyon, impossible de compiler avec `mpicc.openmpi` : ironie du sort, OpenMPI ne connait pas MPI !

```
sbadia@capricorne-6:~/tests_debit_latence$ mpicc.openmpi
    latency_flow_tests.c -o latency_flow_tests
latency_flow_tests.c:22:17: error: mpi.h: No such file or directory
In file included from latency_flow_tests.c:24:
latency_flow_tests.h:28: error: expected '=', ',', ';', 'asm' or '
    __attribute__' before 'BenchType'
latency_flow_tests.h:29: error: expected '=', ',', ';', 'asm' or '
    __attribute__' before 'benchTypeTypes'
latency_flow_tests.h:30: error: expected '=', ',', ';', 'asm' or '
    __attribute__' before 'testTypeTypes'
latency_flow_tests.h:31: error: expected '=', ',', ';', 'asm' or '
    __attribute__' before 'benchTypeDisp'
latency_flow_tests.h:32: error: expected '=', ',', ';', 'asm' or '
    __attribute__' before 'status'
latency_flow_tests.c: In function 'main':
latency_flow_tests.c:60: error: '\gls{MPI}_COMM_WORLD' undeclared (first
    use in this function)
latency_flow_tests.c:60: error: (Each undeclared identifier is reported
    only once
latency_flow_tests.c:60: error: for each function it appears in.)
latency_flow_tests.c: In function 'createBenchType':
latency_flow_tests.c:418: error: '\gls{MPI}_INT' undeclared (first use in
    this function)
[...]
```

Sur Nancy : l'utilisation de MPICH par défaut demande de lancer un programme en tâche de fond. Avec la version OpenMPI (`mpiprun.openmpi`), il est impossible de faire communiquer les nœuds entre eux (comme Lyon, invitations de mot de passe).

Avec l'option `-mca` qui permet de forcer l'utilisation d'un autre protocole d'authentification, l'erreur suivante est rencontrée :

```
p1_15254:  p4_error: interrupt SIGSEGV: 11
rm_l_1_15264: (0.589844) net_send: could not write to fd=5, errno = 32
p2_14980:  p4_error: Found a dead connection while looking for messages: 0
rm_l_2_14990: (0.300781) net_send: could not write to fd=7, errno = 32
p3_7526:  p4_error: net_recv read:  probable EOF on socket: 1
rm_l_3_7536: (0.011719) net_send: could not write to fd=5, errno = 32
```

Déploiements

Les déploiements ne nous ont pas apportés entière satisfaction, ceux-ci auraient pu lisser complètent les problèmes précédents (compilation unique, car même environnement). Mais cela s'est passé autrement. Nous avons souvent rencontré des erreurs assez aléatoires, avec l'outil `kadeploy3`. Cet outil permet en effet de déployer son archive sur les nœuds

passés en paramètres, mais l'étendue de ce logiciel est énorme, puisqu'il s'occupe de faire démarrer les machines, les lancer depuis le réseau, vérifier les archives, les déployer, etc.

Il n'est pas rare de se retrouver avec le fameux message *Node not correctly deploy*, et de recommencer le déploiement pour que cela fonctionne finalement.

Des erreurs ont cependant été résolues, avec l'ajout des contrôleurs propriétaires *(sic)*, mais la réussite du déploiement d'une image vers un autre site reste tout de même aléatoire.

Nous avons aussi utilisé l'outil `kaconsole`, qui permet de prendre le contrôle de la carte Intelligent Platform Management Interface (iPMI). Cette carte est un micro-ordinateur, qui permet de prendre le contrôle total de l'hôte, et donc d'accéder à l'hôte dans le cas où celui-ci ne répondrait plus en *SSH*. Cette interface permet aussi de voir passer le *BIOS*, ce qui est très pratique à distance.

Chapitre 5

Conclusion

L'informatique n'est pas une science exacte,
on n'est jamais à l'abri d'un succès.

1 Répartition du travail

Notre travail s'est divisé en deux équipes, chacune se concentrant sur un objectif particulier : Julien et Sébastien se sont chargés de la mise en place des outils pour l'utilisation des réseaux rapides ainsi que des benchmarks tandis que Guillaume et Luc se sont occupés de l'aspect inventaire du projet.

La formation à l'environnement a été consommatrice de temps et nous a occupé pendant un peu plus de deux semaines. Nous avons ensuite créé les équipes. L'équipe benchmarks a ensuite continué sa formation sur tous les aspects déploiement, réseaux rapides et MPI. Chacun a travaillé sur sa partie, de façon équitable et équilibrée.

Nous avons utilisé un système de version (*SVN*) installé sur un de nos serveurs pour partager nos travaux. Un *wiki* (développé dans le cadre de notre formation de cette année) a également été déployé pour partager nos connaissances, acquises sur l'environnement de Grid5000 et favoriser l'entraide au sein de notre groupe.

2 Problèmes généraux rencontrés

Le réseau de l'IUT ne nous permettant pas de sortir en *SSH* pour atteindre les infrastructures de Grid5000, nous avons dû utiliser le serveur de Julien comme passerelle en sortant sur le *port* 443 avec l'aide de l'outil `corkscrew`.
Il est heureux que le serveur de Julien était déjà configuré pour cette tâche : nous aurions sinon perdu un temps précieux.

Lors de l'utilisation de l'outil `kaconsole3`, le raccourci clavier pour en sortir est différent sur chaque et celui de Grenoble n'était pas documenté sur le *wiki* de Grid5000, occasionnant parfois des arrachages de cheveux (bug soumis aux administrateurs compétents, et résolu).

Le nombre important de maintenances sur les clusters nous a parfois empêché de travailler tel que nous l'avions prévu.

3 Résultats obtenus

Au terme de ce projet, nous constatons que nous avons réussi à satisfaire les différents objectifs qui nous avaient été imposés.

Ainsi, le projet Grid5000 dispose à présent d'outils leur permettant de vérifier automatiquement si le matériel livré est conforme à ce que la description impose. Un administrateur pourra alors compléter l'*OAR database* avec ces informations et lancer le script qui détectera les machines qui ne la respecte pas. Ce qu'on appelle la *recette* pour alors être validée - ou non - en temps et en heure. Avec les tests de benchmarks de disques durs, ceux-ci pourront particulièrement être vérifiés.

Afin de faire le bilan de la bonne interconnexion de tous les nœuds d'un même cluster, le projet dispose à présent d'un programme qui permettra de dresser une matrice complète des latences et débits constatés entre chacun des nœuds. Il sera également maintenant possible d'exporter cette matrice en *YAML* afin d'exploiter les résultats dans d'autres applications. Ou bien, directement utiliser un script que nous leur mettons à disposition pour exporter une page HTML colorée (mise en valeur des extrémités et des quartiles remarquables). Il leur sera aussi possible de tester la charge du réseau en réalisant des bissections au sein du cluster par le biais d'options et d'un second script. A partir des résultats, il sera enfin possible de tracer un graphique de la charge du réseau en fonction du nombre de nœuds, grâce à un dernier script, destiné à `gnuplot`.

Au niveau des réseaux rapides, les paquets Debian construits, ainsi que le tutoriels disponibles sous format LaTeX et PDF, permettront de grandement faciliter la création d'environnements personnalisés qui supportent ces technologies.

Durant notre projet, nous avons également contribué au projet en reportant plusieurs *bugs* dans l'interface prévue à cet effet, et reporté plusieurs problèmes par la liste email des utilisateurs du projet. Enfin, les erreurs de matériels détectées par le biais de notre script d'inventaire ont déjà permises de mettre en évidences de nombreux problèmes sur les différents sites. Un administrateur de Grenoble (Guillaume Ranquet) s'est également intéressé à ce script pour l'utiliser lors d'un événement annuel de Grid5000, et nous a demandé de le rencontrer par visio-conférence au Loria (siège Nancéen de Grid5000).

4 Bénéfices personnels

Pour notre part, ce projet tuteuré aura été une occasion unique de découvrir le monde des grilles de calcul de clusters. Ainsi, nous avons appris à nous familiariser avec son vocabulaire et son fonctionnement, à travers les nombreuses pages de *wiki* du site de Grid5000, les outils OAR, nos recherches personnelles, et évidemment les nombreuses discussions que nous avons entretenues avec notre tuteur de projet.

Nous avons eu le plaisir de grandement nous perfectionner en *C*, de mettre en pratique de façon concrète les cours de *Ruby* enseignés cette année et enfin un perfectionnement de nos connaissances en *Perl*. MPI aura également été une première dans notre expérience de programmeur, puisque c'est une technologie qui s'apparente directement à la programmation pour les Systèmes Multi-Agents (SMA) ou les réseaux Peer-to-Peer (P2P). Nous avons également eu ainsi l'occasion de découvrir les réseaux rapides. Nous avons aussi améliorer nos connaissance dans certains outils *Unix* nécessaire à la détection du matériels ou aux tests des disques durs.

D'un aspect plus humain, ce projet nous aura permis de nous apprendre à gérer une organisation impliquant quatre personnes sur un projet relativement long et complexe. Nous ne comptons pas les soirées passées à faire avancer le projet ou mieux nous former à l'environnement, ainsi que les nombreuses fois où le projet nous a permis de nous retrouver. Nous tenons également à souligner la présence notre tuteur, Lucas Nussbaum, qui a toujours été prompt à nous répondre - parfois très tard - sur la messagerie *Jabber*, par email, à travers la liste des utilisateurs de Grid5000, ou simplement autour d'une bière.

Chapitre 6

Bibliographie

Toute tentative ratée de mettre en évidence la loi de Murphy
est une mise en évidence de la loi de Murphy

Bibliographie

[1] Groupe de refléxion. Grid'5000 plate-forme de recherche experimentale en informatique. Technical report, Inria, Juillet 2003.

[2] Isabelle Belin. Le calcul haute performance est une technologie clé pour l'europe. *La recherche*, Juillet - Août 2009.

[3] Douglas Eadline. *High Performance Computing for Dummie*. Wiley Publishing, Inc, sun and amd special edition edition, 2009.

[4] Michel Serres. La simulation, technique nouvelle, ancienne tradition. *La recherche*, Janvier 2006.

Documents électroniques

[5] http://perldoc.perl.org. Documentation officielle du langage *Perl*.

[6] http://rubybrain.com/. Une API *Ruby* en Javascript.

[7] http://search.cpan.org/. Le site de recherche de modules *Perl* du *CPAN*.

[8] http://www.grid5000.fr. Site officiel du projet Grid5000.

Glossaire

benchmark banc d'essai permettant de mesurer les performances d'un système pour le comparer à d'autres. 6, 11, 22, 39, 40

cluster grappe de serveurs (ou ferme de calcul) constituée de deux serveurs au minimum (appelé aussi nœuds) et partageant une baie de disques commune, pour assurer une continuité de service et/ou repartir la charge de calcul et/ou la charge réseau. 4, 5, 7, 8, 11, 12, 15, 16, 18–22, 25, 28, 30, 32, 36, 40

frontend expression anglaise signifiant frontal, point d'entrée d'un système d'information. 5

grille de calcul infrastructure logicielle et matérielle qui procure à un utilisateur final un accès à des capacités de calcul et de stockage de masse hautement distribué. 1, 4, 40

Acronyms

HCA Host Channel Adapter. 9

HPC High Performance Computing. 4, 9

INRIA Institut National de Recherche en Informatique et Automatique. 7, 8

iPMI Intelligent Platform Management Interface. 38

MPI Message Passing Interface. 21–24, 26–28, 30–32, 36, 37, 39, 41

NetPIPE Network Protocol Independent Performance Evaluator. 24

NFS Network File System. 7, 8

NWS Network Weather Service. 24, 25

OMB OSU Micro-Benchmarks. 22

OSU Ohio State University. 24

P2P Peer-to-Peer. 41

RENATER Réseau National de télécommunications pour la Technologie l'Enseignement et la Recherche. 5, 20

RFC Requests For Comments. 9

SDP Socket Direct Portocol. 9

SMA Systèmes Multi-Agents. 41

SRP SCSI RDMA Protocol. 9

Appendices

1 Script de vérification automatique du matériel

```
#!/usr/bin/perl
#This program is free software: you can redistribute it and/or modify
#it under the terms of the GNU General Public License as published by
#the Free Software Foundation, either version 3 of the License, or
#(at your option) any later version.
#
#This program is distributed in the hope that it will be useful,
#but WITHOUT ANY WARRANTY; without even the implied warranty of
#MERCHANTABILITY or FITNESS FOR A PARTICULAR PURPOSE.  See the
#GNU General Public License for more details.
#
#You should have received a copy of the GNU General Public License
#along with this program.  If not, see <http://www.gnu.org/licenses/>.

use warnings;
use strict;
use lib "lib/lib/perl5";
use YAML;
use XML::Simple;
use Data::Dumper;
use Math::Round;
use Getopt::Long;
use POSIX ":sys_wait_h";

my @criteria;
my $output;
my $help;
my $cow;
my $install;
my $remove;
my $liste_noeuds = $ENV{OAR_FILE_NODES} if (exists $ENV{OAR_FILE_NODES});
# Properties not in the OAR database
my @exclude = qw(disksize diskmodel);
# Properties which have no chance to be identical in OAR database
my @diff = qw(cputype ib10gmodel ib20gmodel myri10gmodel myri2gmodel);
my $error;
## Default list of criteria
my @correct_crit = qw(cluster cpuarch cpucore cpufreq cputype diskmodel disksize
                disktype ib10g ib10gmodel ib20g ib20gmodel
                memnode myri10g myri10gmodel myri2g myri2gmodel
               );

Getopt::Long::GetOptions('o|output=s' => \$output,
                         'f|file=s' => \$liste_noeuds,
                         'p|parameter=s{,}' => \@criteria,
                         'h|help' => \$help,
                         'c|cow' => \$cow,
              'i|install' => \$install,
              'r|remove' => \$remove,
                        );

## Determining the list of the criteria
if ($#criteria < 0) {
  # If no criteria specified, use the default list
  @criteria = @correct_crit;
}
else {
  # Check if the specified criteria are corrects
  my $is_avail = 0;
  foreach my $foo (@criteria) {
    if (!(grep $_ eq $foo, @correct_crit)) {
      print "One of the criteria you specified is not in the list of correct
          criteria.\n",
            "Please check your syntax and restart the program.\n";
      for (@correct_crit) {
        print "$_ \n";
      }
      exit 1;
    }
  }
```

```
70  }
71
72  sub usage {
73    print "Ivcmp - copyright (c) 2010 Guillaume Delourmel <delourmel_guillaume\@yahoo
        .fr>, Luc Didry <lucdidry\@free.fr>\n\n",
74    "Inventory script which compares the informations in the Oar database \n",
75    "and informations returned by Unix tools such as lshw, lspci, etc.\n",
76    "It can be used to see if all the nodes of a cluster have the same material\n\n",
77    "You need a ssh key with an empty passphrase in order to avoid to type the
        passphrase for each node\n",
78    "You need to be root on the nodes in order to get all the required informations
        with lshw\n",
79    "\nUsage : ./ivcmp [OPTIONS]...\n\n",
80    "    -f, --file [FILE]                          specify the file containing the
        list of the nodes (\$OAR_FILE_NODES by default)\n",
81    "                                               This file need to have one node
        per line (duplicate nodes will be ignored)\n",
82    "    -o, --output [FILE]                        print the result in the file in
        YAML format\n",
83    "    -p, --parameter CRITERION [CRITERION]...   check the nodes against specified
        criteria\n",
84    "    -i, --install                              automatically install lshw on
        nodes (lshw is required)\n",
85    "    -r, --remove                               automatically remove the
        directories containing the ouput of the different used tools\n",
86    "    -h, --help                                 print this help and exit\n\n",
87    "List of the correct criteria :\n";
88    for (@correct_crit) {
89      print "  $_\n";
90    }
91  }
92
93
94  ## Recover the node's properties in a hash table (OAR database)
95  sub RecupData {
96    my ($noeud, $sql) = @_;
97    my $file ="$noeud/oar_$noeud.yml";
98
99    # Recover the properties in YAML format
100   system "oarnodes -Y --sql $sql > $file";
101
102   open (FILE, "<", $file) or die("Unable to open file $file");
103
104   my $i = 1;
105   my @numb;
106   # Get the different id of the node in the OAR database
107   while (<FILE>) {
108     my $foo = $_;
109     chomp $foo;
110     if ($foo =~ /^\d*:\s?$/) {
111       push @numb, split(":", $foo);
112     }
113   }
114   close(FILE);
115
116   my $yaml = YAML::LoadFile($file);
117
118   ## Here are the properties we need to check in the OAR database
119   my @listValeur = qw(network_address cluster cpuarch cpucore cputype
120   disktype ethnb ib10g ib10gmodel ib20g ib20gmodel memnode myri10g
121   myri10gmodel myri2g myri2gmodel);
122
123   my %tab_oar;
124   for (@listValeur) {
125     my $temp = Dump($yaml->{$numb[0]}->{$_});
126     $temp =~ s/^--- //;
127     chomp $temp;
128     # Unification of format
129     $temp =~ s/^\s*YES|TRUE\s*$/1/i;
130     $temp =~ s/^\s*NO|FALSE|NONE|~\s*$/~/i;
131     $tab_oar{$_} = $temp;
132   }
133   # Check if all the cpufreq are the same
```

```
134     my $first = 0;
135     for (@numb) {
136       if (!$first) {
137         my $temp = Dump($yaml->{$_}->{'cpufreq'});
138         $temp =~ s/\s|--- //g;
139         chomp $temp;
140         $tab_oar{'cpufreq'} = nearest(0.1, $temp);
141       }
142       else {
143         my $temp = Dump($yaml->{$_}->{'cpufreq'});
144         $temp =~ s/\s|--- //g;
145         chomp $temp;
146         my $cpufreq = nearest(0.1, $temp);
147         if ($tab_oar{'cpufreq'} != $cpufreq) {
148           $tab_oar{"cpufreq_.$first"} = $cpufreq;
149           $error .= "----- The node $noeud has differents frequency on its cores
                 according to the Oar Database -----\n";
150         }
151       }
152       $first++;
153     }
154     return %tab_oar;
155   }
156
157   ## Format lshw file
158   sub etete_lshw {
159     my $done  = 0;
160     my $start = "<node";
161     my ($file) = @_;
162     my $file2 = $file.".tmp";
163     open(FICHIER, "<", $file)   or die("Unable to open file $file");
164     open(FICHIERTMP, ">", $file2) or die("Unable to open file $file2");
165
166     my $disk = 0;
167     my $disk2 = 0;
168     while(defined(my $tmp = <FICHIER>)) {
169       chomp($tmp);
170       if (!$done && "$tmp" =~ /^\s*$start/) {
171         $done = 1;
172         print FICHIERTMP "<perldata>\n";
173       }
174       ## If we have two disks nodes
175       if ($disk && "$tmp" =~ /^.*node id="disk".*$/) {
176         $disk2 = 1;
177       }
178       if (!$disk && "$tmp" =~ /^.*node id="disk".*$/) {
179         $disk = 1;
180       }
181       if (!$disk2) {
182         print FICHIERTMP $tmp."\n" if ($done);
183       }
184       if ($disk2 && "$tmp" =~ /^.*\/node>$/) {
185         $disk2 = 0;
186       }
187     }
188     print FICHIERTMP "</perldata>\n";
189     close(FICHIER);
190     close(FICHIERTMP);
191     rename $file2, $file;
192     return $file;
193   }
194
195   ## Get properties with Unix tools and put them in files
196   sub CreateFiles {
197     my ($noeud) = @_;
198     ## uname
199     system "ssh root\@$noeud -o \"StrictHostKeyChecking no\" uname -nm > $noeud/
          uname_$noeud.txt";
200     ## lspci
201     system "ssh root\@$noeud lspci > $noeud/lspci_$noeud.txt";
202     ## cat /proc/cpuinfo
203     system "ssh root\@$noeud cat /proc/cpuinfo > $noeud/cpuinfo_$noeud.txt";
204     ## lshw
```

```
205     system "ssh root\@$noeud lshw -xml -C disk -C memory -C network -C processor >
            $noeud/lshw_$noeud.xml";
206     ## ifconfig
207     system "ssh root\@$noeud ifconfig > $noeud/ifconfig_$noeud.txt";
208   }
209
210   ## Gathers informations of Unix tools
211   sub ParseFiles {
212     my ($noeud) = @_;
213     my %properties;
214     my @listValeur = qw(network_address cluster cpuarch cpucore cpufreq cputype
215     disktype ethnb ib10g ib10gmodel ib20g ib20gmodel memnode myri10g
216     myri10gmodel myri2g myri2gmodel disksize);
217     # Format the lshw file
218     my $tmp_xml_lshw = etete_lshw("$noeud/lshw_$noeud.xml");
219     # We define "id" as a key for the element
220     my $xml = new XML::Simple (KeyAttr=>'id');
221     my $oar = $xml->XMLin($tmp_xml_lshw);
222
223     $properties{cputype} = $oar->{node}->{"cpu:0"}->{product};
224     $properties{cputype} =~ s/(\s+)/ /g;
225     ##################################
226     $properties{memnode} = $oar->{node}->{"memory"}->{size}->{content};
227     if (!defined($properties{memnode})) {
228       my $i = 0;
229       while (defined($oar->{node}->{"memory:$i"})) {
230         my $j = 0;
231         while (defined($oar->{node}->{"memory:$i"}->{node}->{"bank:$j"})) {
232       if (my $temp2 = $oar->{node}->{"memory:$i"}->{node}->{"bank:$j"}->{size}->{
              content}) {
233         $properties{memnode} += $temp2;
234       }
235       $j++;
236         }
237         $i++;
238       }
239     }
240     $properties{memnode} = nearest(512, $properties{memnode}/1024/1024);
241     ##################################
242     $properties{disksize} = $oar->{node}->{"disk"}->{size}->{content};
243     if (!defined($properties{disksize})) {
244       my $i = 0;
245       while (exists $oar->{node}->{"disk:$i"}) {
246         if (!defined($properties{diskmodel})) {
247           $properties{diskmodel} = $oar->{node}->{"disk:$i"}->{product};
248 #         if (!defined($properties{diskmodel})) {
249 #       $properties{diskmodel} = $oar->{node}->{"disk:$i"}->{description};
250 #         }
251         }
252         if (defined($oar->{node}->{"disk:$i"}->{size}->{content})) {
253       $properties{disksize} += $oar->{node}->{"disk:$i"}->{size}->{content};
254         }
255         $i++;
256       }
257     }
258     else {
259       $properties{diskmodel} = $oar->{node}->{"disk"}->{product};
260       if (!defined($properties{diskmodel})) {
261         $properties{diskmodel} = $oar->{node}->{"disk"}->{description};
262       }
263     }
264     chomp $properties{disksize};
265     $properties{disksize} = round($properties{disksize}/1000000000);
266     ##################################
267     my $i = 0;
268     while (exists $oar->{node}->{"cpu:$i"}) {
269       my $cpu = $oar->{node}->{"cpu:$i"}->{size}->{content};
270       chomp $cpu;
271       $cpu = $cpu/1000000000;
272       $cpu = nearest(.1, $cpu);
273       if (!$i) {
274         $properties{cpufreq} = $cpu;
275       }
```

```
276       else {
277         if ($cpu != $properties{cpufreq}) {
278           $properties{"cpufreq_$i"} = $cpu;
279           $error .= "----- The node $noeud has differents frequency on its cores
                according to the received data -----\n";
280         }
281       }
282       $i++;
283     }
284     ## uname
285     open(UNAME, "<", "$noeud/uname_$noeud.txt") or die ("Unable to open file $noeud/
          uname_$noeud.txt : $!\n");
286     while (defined(my $foo = <UNAME>)) {
287       chomp $foo;
288       ($properties{network_address}, $properties{cpuarch}) = split(" ", $foo);
289       $properties{cluster} = $1 if($properties{network_address} =~ /^([^-]*)-.*$/);
290     }
291     close(UNAME);
292
293     ## cpuinfo
294     open(CPUINFO, "<", "$noeud/cpuinfo_$noeud.txt") or die ("Unable to open file
          $noeud/cpuinfo_$noeud.txt : $!\n");
295     while (defined(my $foo = <CPUINFO>)) {
296       chomp $foo;
297       $properties{cpucore} = $1 if ($foo =~ /core\sid\s*:\s([0-9])/i);
298     }
299     close(CPUINFO);
300     $properties{cpucore}++;
301
302     ## lspci
303     open(LSPCI, "<", "$noeud/lspci_$noeud.txt") or die ("Unable to open file $noeud/
          lspci_$noeud.txt : $!\n");
304     while (defined(my $foo = <LSPCI>)) {
305       chomp $foo;
306       if ($foo =~ /(MT23108|MT25208|MT25408|MNEH18-XTC|MT25418)/i) {
307         $properties{ib10g} = 1;
308         $properties{ib10gmodel} = $1;
309       }
310       if ($foo =~ /(MHGH29-XTC|MT26418)/i) {
311         $properties{ib20g} = 1;
312         $properties{ib20gmodel} = $1;
313       }
314       if ($foo =~ /(10G-PCIE-8A)/i) {
315         $properties{myri10g} = 1;
316         $properties{myri10gmodel} = $1;
317       }
318       if ($foo =~ /(M3F-PCIXD-2|M3F-PCIXF-2|Myrinet 2000)/i) {
319         $properties{myri2g} = 1;
320         if ($1 =~/(M3F-PCIXD-2|M3F-PCIXF-2)/i) {
321       $properties{myri2gmodel} = $1;
322         }
323         else {
324       $error .= "----- The Unix tools don't say the Myri2G model. Please look at the
              OAR Database  -----\n";
325         }
326       }
327
328       $properties{disktype} = `egrep -i -m 1 "sas|sata|scsi" $noeud/lspci_$noeud.txt
            `;
329       if (!($properties{disktype} =~ s/^.*(sas|sata|scsi).*$/$1/i)) {
330         $properties{disktype} = `egrep -i -m 1 "ide" $noeud/lspci_$noeud.txt`;
331         $properties{disktype} =~ s/^.*(ide).*$/$1/i;
332       }
333       chomp($properties{disktype});
334       $properties{disktype} = lc($properties{disktype});
335
336       ## ifconfig
337       my $inet = `grep -c "inet addr" $noeud/ifconfig_$noeud.txt`;
338       my $lo = `grep -c -e "lo[ ]" $noeud/ifconfig_$noeud.txt`;
339       chomp $inet;
340       chomp $lo;
341       $properties{ethnb} = $inet - $lo;
342     }
```

```
343     close(LSPCI);
344
345     for (@listValeur) {
346       $properties{$_} = "~" if (!$properties{$_});
347       chomp $properties{$_};
348     }
349     return %properties;
350   }
351
352   ################################################################################
353   #                        Beginning of the main program
354   ################################################################################
355   if ($help)
356   {
357     &usage;
358     exit 0;
359   }
360
361   my $answer = "42";
362   ## Check if the output file already exists
363   if ($output) {
364     if (-e $output) {
365       while ($answer !~ /^(y||n)$/i) {
366         print "The output file already exists. Do you want to overwrite it ? (Y\/n) "
                ;
367         $answer = <STDIN>;
368         chomp $answer;
369         if ($answer eq "") {
370           $answer = "Y";
371         }
372         elsif ($answer !~ /^y|n/i) {
373           print "You need to answer y or n !\n";
374         }
375       }
376     }
377     if (lc($answer) eq "n") {
378       print "You don't want to overwrite the ouput file : aborting the program\n";
379       exit 0;
380     }
381   }
382
383   ## Recovery of the reserved nodes list
384   open (LISTE_NOEUDS, "<", $liste_noeuds) or die("Unable to open file $liste_noeuds :
          $!\n");
385
386   ## Get a hash of nodes' name and create sql request parameters
387   my %liste_noeuds;
388   while (defined(my $foo = <LISTE_NOEUDS>)) {
389     chomp $foo;
390     $liste_noeuds{$foo} = "\"network_address='$foo'\"";
391   }
392   close(LISTE_NOEUDS);
393
394   ## Get a hash of nodes' name with a hash of their properties
395   my @liste_noeuds = keys %liste_noeuds;
396   # Hash of the properties returned by the OAR Database
397   my %properties_oar;
398   # Hash of the properties returned by the Unix tools
399   my %properties_parse;
400   # Automatic install of lshw on deployed nodes
401   my $pid;
402   for (@liste_noeuds) {
403     my $foo = $_;
404     $pid = fork();
405     # Children
406     if ($pid == 0) {
407       my $ping = system "ping $foo -c 1 &>/dev/null";
408       $ping >>= 8;
409       if ($ping) {
410         delete $liste_noeuds{$foo};
411       }
412       else {
413         if ($install) {
```

```
414       `ssh root\@$foo -o \"StrictHostKeyChecking no\" \"apt-get update &>/dev/null &&
              apt-get install lshw -y &>/dev/null\"`
415         }
416         unless (-d $foo && -e $foo) {
417       mkdir ($foo) or die ("Unable to create directory $foo : $!\n");
418         }
419         &CreateFiles($foo);
420       }
421       exit(0);
422     }
423   }
424   # Parent
425   if ($pid != 0) {
426     do {
427       $pid = waitpid(-1,&WNOHANG);
428     }
429     until ($pid == -1);
430   }
431
432   for (@liste_noeuds) {
433     my $foo = $_;
434     my $ping = system "ping $foo -c 1 &>/dev/null";
435     $ping >>= 8;
436     if ($ping) {
437       delete $liste_noeuds{$foo};
438     }
439     else {
440       ## Get Oar database infos and put them in some files
441       my %temp = &RecupData($foo, $liste_noeuds{$foo});
442       $properties_oar{$foo} = \%temp;
443
444       ## Get node infos (Unix tools)
445       my %temp2 = &ParseFiles($foo);
446       $properties_parse{$foo} = \%temp2;
447
448       ## Compare oar's properties and nodes' properties
449       my $oar = $properties_oar{$foo};
450       my $parse = $properties_parse{$foo};
451       for (keys %$parse) {
452         my $titi = $_;
453         my $exclude = 0;
454         my $diff = 0;
455         for (@exclude) {
456       $exclude = 1 if ("$_" eq "$titi");
457         }
458         for (@diff) {
459       $diff = 1 if ("$_" eq "$titi");
460         }
461         if (!$exclude && exists $oar->{$titi} && $parse->{$titi} ne $oar->{$titi}) {
462       # Add an error message if there is a difference and this is not predictable
463       $error .= "------ The Oar database $titi information of the node $foo is not the
              same as we check on the node ------\n".
464             "      OAR database : $oar->{$titi}          Unix tools : $parse->{$titi
                  }\n" if !$diff;
465         }
466       }
467     }
468   }
469
470   ## Check if the nodes are identical, based on the criteria list
471   #  Here we use the Unix tools list since it's more complete
472   #  and more reliable
473   my $first = "42";
474   my %resultat;
475   #delete $properties_oar{""};
476   for (keys %properties_oar) {
477     my $foo = $_;
478     my $parse = $properties_parse{$foo};
479     # Firt node : first group
480     if ($first) {
481       $resultat{"1"}->{"nodes"}->{$foo} = "~";
482       foreach my $bar (@criteria) {
483         $resultat{"1"}->{"$bar"} = $parse->{$bar}
```

```
484       }
485       $first = 0;
486     }
487     else {
488       my $groupe;
489       my @temp = keys %resultat;
490       # Compare to all groups
491       for (@temp) {
492         my $key = $_;
493         my $ok = "42";
494         for (@criteria) {
495           my $bar = $_;
496           if ($resultat{"$key"}->{"$bar"} ne $parse->{"$bar"}) {
497             $ok = 0;
498             last;
499           }
500         }
501         # If all criteria are ok, we're in the good group
502         if ($ok){
503           $groupe = $key;
504           last;
505         }
506         else {
507       $groupe = 0;
508         }
509       }
510       # Creation of a new group if we need
511       if (!$groupe) {
512         $groupe = $#temp + 2;
513         for (@criteria) {
514           my $bar = $_;
515           $resultat{"$groupe"}->{"$bar"} = $parse->{$bar};
516         }
517       }
518       # Put the node in its group
519       $resultat{"$groupe"}->{"nodes"}->{$foo} = "~";
520     }
521   }
522
523   if ($cow) {
524     print "
          _____________________________________________________________________________
         \n",
525           "\/
                \\\n";
526   }
527   print "--- Notice that the printed value are from Unix tools, not from OAR database
        ---\n";
528   ## Prepare the results to be print
529   my $out;
530   for (sort keys %resultat) {
531     # group
532     $out .= "$_ :\n";
533     my $bar = $resultat{$_};
534     for (@criteria) {
535       $out .= "  $_ : $bar->{$_}\n";
536     }
537     $out .= "  nodes :\n";
538     my $nodes = $bar->{"nodes"};
539     for (sort keys %$nodes) {
540       $out .= "    $_ : $nodes->{$_}\n";
541     }
542   }
543   ## Print results (in YAML format)
544   if (!$output) {
545     print $out;
546   }
547   else {
548     # Print results (in YAML format) in a specified file
549     open (OUT, ">", $output)  or die("Unable to open file $output");
550     print OUT $out;
551     if ($cow) {
```

```
552         print "|                          Bazinga !                          |\n";
553     }
554     close(OUT);
555 }
556
557 ## Print errors (properties differences between OAR and Unix tools)
558 print $error unless !defined($error);
559 if ($cow) {
560     print "\\
          _____________________________________________________________________
          \/\n",
561     "          \\   ^__^\n",
562     "           \\  (oo)\\_______\n",
563     "              (__)\\       )\\\/\\\n",
564     "                  ||----w |\n",
565     "                  ||     ||\n";
566 }
567
568 ## Remove the nodes' directories
569 if ($remove) {
570     for (keys %liste_noeuds) {
571         `rm -rf $_`;
572     }
573 }
```

2 README du script ivcmp

```
1  ##############################################################################
2  ##############################################################################
3
4  WHAT IS IVCMP ?
5
6  Ivcmp is a Perl script which gets hardware informations from the reserved nodes,
7  compares them to the OAR Database and determines if all nodes have the same
8  hardware.
9  It uses lshw, ifconfig, lspci, uname and /proc/cpuinfo to get the informations
10 from the nodes.
11 The output shows you the nodes sorted in groups made by nodes which have
12 exactly the same material, in YAML format. The hardware informations used to
13 compare the nodes are :
14    cluster        : name of the cluster the node belongs to
15    cpuarch        : architecture (x86_64 by ex.)
16    cpucore        : number of cores by CPU
17    cpufreq        : frequency of the CPUs
18    cputype        : type of CPU
19    diskmodel      : model of hard disk drive
20    disksize       : size of hard disk drive
21    disktype       : hard disk drive interface
22    ib10g          : do the node has an Infiniband 10g card ?
23    ib10gmodel     : which model ?
24    ib20g          : do the node has an Infiniband 20g card ?
25    ib20gmodel     : which model ?
26    memnode        : ram quantity
27    myri10g        : do the node has a Myrinet 10g card ?
28    myri10gmodel   : which model ?
29    myri2g         : do the node has a Myrinet 2g card ?
30    myri2gmodel    : which model ?
31
32 The differences with the OAR Database will be displayed at the end of the YAML
33 output.
34 You can specify a file where to store the YAML output.
35
36 ##############################################################################
37 ##############################################################################
38
39 HOW TO USE IT ?
40
41 You need a ssh key with an empty passphrase in order to avoid to type the
42 passphrase for each node.
43 You need to be root on the nodes in order to get all the required informations
44 with lshw.
45
```

```
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
 -i, --install
    automatically install lshw on nodes
 -r, --remove
    automatically remove the directories containing the ouput of the different
    used tools
 -h, --help
    print help and exit

List of the correct criteria : see the list above

Example of inconsistency warning :

------ The Oar database disktype information of the node
    capricorne-54.lyon.grid5000.fr is not the same as we check on the node ------
      OAR database : scsi           Unix tools : sata

Example of YAML output :

1 :
  cluster : sagittaire
  cpuarch : x86_64
  cpucore : 1
  cpufreq : 2.4
  cputype : AMD Opteron(tm) Processor 250
  diskmodel : MAT3073NC
  disksize : 74
  disktype : scsi
  ib10g : ~
  ib10gmodel : ~
  ib20g : ~
  ib20gmodel : ~
  memnode : 2048
  myri10g : ~
  myri10gmodel : ~
  myri2g : ~
  myri2gmodel : ~
  nodes :
    sagittaire-39.lyon.grid5000.fr : ~
    sagittaire-42.lyon.grid5000.fr : ~
    sagittaire-44.lyon.grid5000.fr : ~
    sagittaire-45.lyon.grid5000.fr : ~
    sagittaire-46.lyon.grid5000.fr : ~
    sagittaire-48.lyon.grid5000.fr : ~
    sagittaire-52.lyon.grid5000.fr : ~
    sagittaire-53.lyon.grid5000.fr : ~
    sagittaire-54.lyon.grid5000.fr : ~
    sagittaire-61.lyon.grid5000.fr : ~
    sagittaire-63.lyon.grid5000.fr : ~
    sagittaire-66.lyon.grid5000.fr : ~
2 :
  cluster : capricorne
  cpuarch : x86_64
  cpucore : 1
  cpufreq : 2
  cputype : AMD Opteron(tm) Processor 246
  diskmodel : SCSI Disk
  disksize : 36
  disktype : sata
  ib10g : ~
  ib10gmodel : ~
  ib20g : ~
  ib20gmodel : ~
  memnode : 2048
```

```
    myri10g : ~
    myri10gmodel : ~
    myri2g : 1
    myri2gmodel : ~
    nodes :
      capricorne-33.lyon.grid5000.fr : ~
      capricorne-34.lyon.grid5000.fr : ~
      capricorne-35.lyon.grid5000.fr : ~
      capricorne-36.lyon.grid5000.fr : ~
      capricorne-37.lyon.grid5000.fr : ~
      capricorne-38.lyon.grid5000.fr : ~
      capricorne-39.lyon.grid5000.fr : ~
      capricorne-40.lyon.grid5000.fr : ~
      capricorne-41.lyon.grid5000.fr : ~
```

3 Script de benchmark des disques durs

```
#!/usr/bin/perl
#This program is free software: you can redistribute it and/or modify
#it under the terms of the GNU General Public License as published by
#the Free Software Foundation, either version 3 of the License, or
#(at your option) any later version.
#
#This program is distributed in the hope that it will be useful,
#but WITHOUT ANY WARRANTY; without even the implied warranty of
#MERCHANTABILITY or FITNESS FOR A PARTICULAR PURPOSE.  See the
#GNU General Public License for more details.
#
#You should have received a copy of the GNU General Public License
#along with this program.  If not, see <http://www.gnu.org/licenses/>.
use warnings;
use strict;
use lib "lib/lib/perl5";
use POSIX ":sys_wait_h";
use Getopt::Long;
use Math::Round;

my $install;
my $help;
my $output;
my $type;
my $filelist;
my $remove;
Getopt::Long::GetOptions('f|file=s' => \$filelist,
                         'h|help' => \$help,
                         'y|yaml' => \$type,
                         'r|remove' => \$remove,
                         'o|output=s' => \$output,
                         'i|install' => \$install,
                        );

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

if ($help)
{
  &usage;
  exit 0;
```

```
51  }
52
53  if(!$output){
54    $output="bonnie.yml";
55  }
56
57  my $answer = "42";
58  ## Check if the output file already exists
59  if ($output) {
60    if (-e $output) {
61      while ($answer !~ /^(y||n)$/i) {
62        print "The output file already exists. Do you want to overwrite it ? (Y\/n) "
              ;
63        $answer = <STDIN>;
64        chomp $answer;
65        if ($answer eq "") {
66          $answer = "Y";
67        }
68        elsif ($answer !~ /^y|n/i) {
69          print "You need to answer y or n !\n";
70        }
71      }
72    }
73    if (lc($answer) eq "n") {
74      print "You don't want to overwrite the ouput file : aborting the program\n";
75      exit 0;
76    }
77  }
78  my %liste_noeuds;
79  my $liste_noeuds;
80  if($filelist){
81  # Recovery of the nodes list specified by User
82    open (LISTE_NOEUDS, "<", $filelist) or die("Unable to open file $filelist : $!\n"
          );
83    while (defined(my $foo = <LISTE_NOEUDS>)) {
84      chomp $foo;
85      $liste_noeuds{$foo} = "";
86    }
87    close(LISTE_NOEUDS);
88  }else{
89  # Recovery of the reserved nodes list
90    $liste_noeuds = $ENV{OAR_FILE_NODES} if (exists $ENV{OAR_FILE_NODES});
91    open (LISTE_NOEUDS, "<", $liste_noeuds) or die("Unable to open file $liste_noeuds
          : $!\n");
92    # Get a hash of nodes' name and create sql request parameters
93    while (defined(my $foo = <LISTE_NOEUDS>)) {
94      chomp $foo;
95      $liste_noeuds{$foo} = "";
96    }
97    close(LISTE_NOEUDS);
98  }
99
100 # Automatic install of Bonnie++ on deployed nodes
101 my @liste_noeuds = keys %liste_noeuds;
102
103
104 ## Launch the hard disk drive test in parallele on the deployed node
105 my $pid;
106 foreach (@liste_noeuds){
107   my $node=$_;
108   $pid = fork();
109   if ($pid == 0) {
110     if($install){
111   print "Install on $node\n";
112         system("ssh root\@$node -o \"StrictHostKeyChecking no\"  \"apt-get update
              &>/dev/null && apt-get install bonnie++ -y &>/dev/null\"");
113     }
114    system("ssh root\@$node \"free -m | grep Mem\" > $node.mem");
115     my $ram;
116     open(MEMFILE,"<","$node.mem") or die("Unable to open file $node.mem");
117     while (defined(my $foo = <MEMFILE>)){
118   if($foo =~ /^Mem:\s*(\w*)\s*/){
119           $ram= $1;
```

```
120     }
121       }
122       $ram=$ram*2;
123       system("ssh root\@$node \"bonnie++ -s $ram -d /tmp -m $node -u root\"> $node.
              txt");
124       exit;
125     }
126
127   }
128   if ($pid != 0) {
129     do
130     {
131       $pid = waitpid(-1,&WNOHANG);
132     }
133     until ($pid == -1);
134   }
135   my $txt="";
136
137   ##Build the output file
138   if($type){
139     my $moyenne_ecriture=0;
140     my $moyenne_lecture=0;
141     my $moyenne_nbop=0;
142     foreach (@liste_noeuds){
143       open(FICHIER, "<", "$_.txt") or die("Unable to open file $_.txt");
144       while(defined(my $foo = <FICHIER> )){
145         if($foo =~ /(.*\.grid5000.fr),\w*,\w*,\w*,(\w*),\w*,\w*,\w*,\w*,\w*,(\w*),\w
                *,(\w*.\w),.*/){
146           my $ecr=$2;
147           my $lec=$3;
148           my $nbo=$4;
149           $txt="$txt$1\n";
150           $txt="$txt  writing: $ecr\n";
151           $txt="$txt  reading: $lec\n";
152           $txt="$txt  number_of_operations: $nbo\n";
153           $moyenne_ecriture = $moyenne_ecriture+$ecr;
154           $moyenne_lecture = $moyenne_lecture+$lec;
155           $moyenne_nbop = $moyenne_nbop+$nbo;
156         }
157       }
158     }
159     $moyenne_ecriture = $moyenne_ecriture / @liste_noeuds;
160     $moyenne_lecture = $moyenne_lecture / @liste_noeuds;
161     $moyenne_nbop = $moyenne_nbop / @liste_noeuds;
162
163     $moyenne_ecriture = nearest(0.1,$moyenne_ecriture);
164     $moyenne_lecture = nearest(0.1,$moyenne_lecture);
165     $moyenne_nbop = nearest(0.1, $moyenne_nbop);
166     $txt="Average_number_of_operations: $moyenne_nbop\n$txt";
167     $txt="Average_speed_of_reading: $moyenne_lecture\n$txt";
168     $txt="Average_speed_of_writing: $moyenne_ecriture\n$txt";
169
170   }else{
171     my $moyenne_ecriture=0;
172     my $moyenne_lecture=0;
173     my $moyenne_nbop=0;
174
175     $txt="\t\tNode\t\t\t|Writing\t|Reading\t|Number_of_operations\n";
176     foreach (@liste_noeuds){
177       open(FICHIER, "<", "$_.txt") or die("Unable to open file $_.txt");
178       while(defined(my $foo = <FICHIER> )){
179         if($foo =~ /(.*\.grid5000.fr),\w*,\w*,\w*,(\w*),\w*,\w*,\w*,\w*,\w*,(\w*),\w
                *,(\w*.\w),.*/){
180           my $taille=0;
181           my $bar=$1;
182           my $ecr=$2;
183           my $lec=$3;
184           my $nbo=$4;
185       $txt ="$txt$1\t";
186           $taille++ while ($bar =~ /(.)/g);
187           if($taille<24){
188             $txt ="$txt\t\t|";
189           }elsif($taille>32){
```

```
190             $txt ="$txt|";
191           }else{
192             $txt ="$txt\t|";
193           }
194           $txt ="$txt$ecr\t\t|$lec\t\t|$nbo\n";
195           $moyenne_ecriture = $moyenne_ecriture+$ecr;
196           $moyenne_lecture = $moyenne_lecture+$lec;
197           $moyenne_nbop = $moyenne_nbop+$nbo;
198         }
199       }
200
201     }
202     $moyenne_ecriture = $moyenne_ecriture / @liste_noeuds;
203     $moyenne_lecture = $moyenne_lecture / @liste_noeuds;
204     $moyenne_nbop = $moyenne_nbop / @liste_noeuds;
205
206     $moyenne_ecriture = nearest(0.1,$moyenne_ecriture);
207     $moyenne_lecture = nearest(0.1,$moyenne_lecture);
208     $moyenne_nbop = nearest(0.1, $moyenne_nbop);
209
210     $txt="Average_number_of_operations: $moyenne_nbop\n$txt";
211     $txt="Average_speed_of_reading: $moyenne_lecture\n$txt";
212     $txt="Average_speed_of_writing: $moyenne_ecriture\n$txt";
213
214   }
215   open (FICHIERYAML,">",$output)or die("Unable to open file : $output");
216   print FICHIERYAML $txt;
217   close(FICHIERYAML);
218
219
220   if($remove){
221     foreach (@liste_noeuds){
222       `rm $_.mem $_.txt`;
223     }
224   }
```

4 README du script ivbon

```
1  ##############################################################################
2  ##############################################################################
3
4  WHAT IS IVBON ?
5
6  Ivbon is a script to check the hard disk drive performance for the different
7  node on the cluster of Grid5000.
8  This is a perl script who use the Bonnie++ tools to perform the test, it
9  connects to the different nodes previously reserved and tests their hard disk
10 drive after the script summarizes the informations.
11 This may take a long time according to the memory ram use to make the test
12 because Bonnie++ take a file size which make the double of memory size to
13 perform the test.
14
15 ##############################################################################
16 ##############################################################################
17
18 HOW TO USE ?
19
20 The first time use the script with option -i to install Bonnie++ on the node,
21 then you can use the differents options like :
22  -y       :   to have a yaml output
23  -o file  :   to precise the name of output file
24  -h       :   to print the help
25  -f file  :   specified the node name in a file
26  -r       :   remove the temporary file create by the script
27
28 At the end of the script you can have the result in Yaml (use -y) :
29
30     Average_speed_of_writing: 30862
31     Average_speed_of_reading: 66291.3
32     Average_number_of_operations: 205.3
33     grelon-33.nancy.grid5000.fr
34       writing: 31076
```

```
35        reading: 68539
36        Number_of_operations: 207.8
37      grelon-34.nancy.grid5000.fr
38        writing: 30361
39        reading: 63508
40        Number_of_operations: 208.7
41      grelon-35.nancy.grid5000.fr
42        writing: 31149
43        reading: 66827
44        Number_of_operations: 199.4
45
46  or in text :
47
48      Average_speed_of_writing: 30774.3
49      Average_speed_of_reading: 63275.7
50      Average_number_of_operations: 190.4
51                  Node                    |writing     |Reading         |
                        Number_of_operations
52      grelon-33.nancy.grid5000.fr         |31268       |65192           |186.8
53      grelon-34.nancy.grid5000.fr         |29966       |60931           |190.2
54      grelon-35.nancy.grid5000.fr         |31089       |63704           |194.3
```

5 Benchmark de Latence et Débit

```
1   /*
2    * OAR LATENCY FLOW TESTS
3    *
4    * Cree une matrice des debits et latence entre chaque noeud (sauf le rank 0) de l'
       execution MPI, dans les deux sens,
5    * ou separe la liste des noeuds en deux pour faire une bissection.
6    *
7    * OPTIONS : Voir -h
8    *
9    * AUTEURS : <julien@vaubourg.com>
10   *       <seb@sebian.fr> <badia.seb@gmail.com>
11   *
12   * 2010, pour Grid5000
13   *
14   */
15
16  #include <stdio.h>
17  #include <stdlib.h>
18  #include <string.h>
19  #include <time.h>
20  #include <unistd.h>
21  #include <math.h>
22  #include <mpi.h>
23
24  #include "latency_flow_tests.h"
25
26  /* A compiler avec un compilateur MPI et a executer avec une commande de la meme
       categorie, sur une reservation de 3 noeuds ou plus */
27  int main(int argc, char** argv) {
28      int
29          rank, /* Numero du noeud qui execute le script, par rapport au nb de noeuds
                concernes par l'execution */
30          nbNodes, /* Nombre de noeuds concernes par l'execution du programme */
31          pktSize, /* Taille du mot qui sera envoye pour faire les tests de debit */
32          nbRetry, /* Nb de fois qu'un test sera recommence afin d'augmenter la
                precision */
33          bissection, /* Mode bissection ? */
34          randBiss, /* Mode bissection, avec formation des paires aleatoires ? */
35          yaml, /* Sortie dans un fichier YAML (yamlFile) en plus de la matrice ? */
36          gnuplot, /* Sortie pour un graphique gnuplot plutot qu'une matrice ? */
37          i, sender, recver, l; /* Divers compteurs */
38      float
39          sumLatency, /* Somme de toutes les latences d'un meme test afin de pouvoir
                faire la moyenne */
40          sumFlow; /* Idem pour le debit */
41      YourTest
42          *bissTests, /* Tableau de tous les tests a envoyer, sert pour le rank 0 */
43          myTest; /* Test que recevra le noeud si il n'est pas le rank 0 */
```

```
44      Bench
45          *sameBenchs; /* Tableau qui recevra tous les resultats des benchs d'un meme
                test, a partir desquels on fera des moyennes */
46      MyResult
47          myResult, /* Resultat que fabriquera le noeud a partir de son test, si il n
                'est pas le rank 0 */
48          *bissResults, /* Tableau final contenant tous les resultats des tests, dont
                l'indice indique le rank du sender du test */
49          **benchResults; /* Idem mais a deux dimensions : en y le sender, en x le
                receveur. Ne sert aussi que pour le rank 0 */
50      StatsResult
51          latencyStats, /* Pointeurs vers les benchs ayant enregistres les latences
                min et max, ainsi que la somme de toutes les latences et la moyenne */
52          flowStats; /* Idem pour les debits */
53      char
54          yamlFile[50]; /* Nom du fichier qui accueillera la sortie YAML si l'option
                -o est passee */
55
56
57      /* Initialisation des connexions MPI et recuperation du nb de noeuds concernes
            par l'execution
58      ainsi que le numero - rang - du noeud courant courant */
59      MPI_Init(&argc, &argv);
60          MPI_Comm_size(MPI_COMM_WORLD, &nbNodes);
61          MPI_Comm_rank(MPI_COMM_WORLD, &rank);
62
63      /* Prise en compte des differentes options passees au script */
64      initOptions(argc, argv, nbNodes, rank, &pktSize, &nbRetry, &bissection, &
            randBiss, &gnuplot, &yaml, yamlFile);
65
66      /*  Le buffer sert pour envoyer ou recevoir le mot qui sert de test au debit */
67      buffer = (int *) malloc(sizeof(int)*pktSize);
68      l = 0;
69
70      if(buffer == NULL) {
71          fprintf(stderr, "ERROR: Can't allocate memory.");
72          exit(1);
73      }
74
75      /* Creation des structures qui pourront dorenavant transiter d'un noeud a l'
            autre avec MPI */
76      createBenchType();
77      createTestType();
78      createResultType();
79
80      /* Le MASTER est le rank 0, c'est lui qui enverra les tests, qui recevra les
            resultats et qui les affichera.
81      Il ne fait pas parti des tests. */
82      if(rank == MASTER) {
83
84          /* Le mode bissection (option -b) consiste a creer des paires de noeuds
                dans ceux faisant parti de l'execution du programme
85          et faire envoyer un mot d'un noeud a l'autre, en demarrant tous en meme tps
                */
86          if(bissection) {
87              bissTests = (YourTest*) malloc(sizeof(YourTest)*nbNodes);
88              bissResults = (MyResult*) malloc(sizeof(MyResult)*nbNodes);
89
90              if(bissTests == NULL || bissResults == NULL) {
91                  fprintf(stderr, "ERROR: Can't allocate memory.");
92                  exit(1);
93              }
94
95              /* Si l'option -rb est active, alors les formations de paires se feront
                    aleatoirement parmis les noeuds dispo */
96              if(randBiss)
97                  bissPrepareAllRandTests(bissTests, nbNodes);
98
99              /* Sinon, elles se font en coupant le nombre de noeuds en deux et en
                    prenant le premier de la premiere moitie et le
100             premier de la seconde, et ainsi de suite */
101             else
102                 bissPrepareAllTests(bissTests, nbNodes);
```

```
103
104             /* Transmission des tests prepares aux interesses : c'est une fonction
                    collective, ce qui signifie que tous les noeuds
105             doivent avoir execute cette meme fonction, et etre en attente de cet
                    appel du rank 0 (sinon, ils seront attendus).
106             Une fois que chacun a recu son test, chacun connait son role dans la
                    transaction : envoyeur ou receveur. Chacun se met
107             en ecoute du rank 0 pour savoir quand il devra commencer a jouer son
                    role. */
108             bissTransmitAllTests(bissTests, &myTest);
109
110             /* Chaque noeud est en ecoute de cette meme fonction (puisque c'est
                    aussi une fonction collective). Elle envoi un mot vide
111             en broadcast a tous pour leur dire que le jeu debute : les receveurs se
                     mettent a ecouter les envoyeurs, et les envoyeurs
112             envoient aux receveurs. Chacun se remet ensuite en ecoute du rank 0, et
                     ce jusqu'a ce que la precision imposee par nbRetry
113             soit atteinte. */
114             for(i = 0; i < nbRetry; i++)
115                 bissLaunchAllTests();
116
117             /* Derniere fonction collective : tout le monde envoi son resultat,
                    seuls les resultats des envoyeurs auront de l'interet */
118             bissTransmitAllResults(bissResults, &myResult);
119
120         /* Le contraire du mode bissection est le mode matrice : chaque noeud
                envverra un noeud a tous les autres, afin de pouvoir creer
121         une matrice complete des performances entre tous les noeuds concerne par l'
                execution, dans tous les sens */
122         } else {
123
124             benchResults = (MyResult**) malloc(sizeof(MyResult*)*nbNodes);
125
126             if(benchResults == NULL) {
127                 fprintf(stderr, "ERROR: Can't allocate memory.");
128                 exit(1);
129             }
130
131             for(i = 0; i < nbNodes; i++) {
132                 benchResults[i] = (MyResult*) malloc(sizeof(MyResult)*nbNodes);
133
134                 if(benchResults[i] == NULL) {
135                     fprintf(stderr, "ERROR: Can't allocate memory.");
136                     exit(1);
137                 }
138             }
139
140             for(sender = 1; sender < nbNodes; sender++) {
141
142                 /* Preparation des tests pour le noeud envoyeur : mise en ecoute de
                        ce noeud, pour tous les autres
143                 noeuds qui recevront tour a tour un mot de lui. Chacun de ces
                        noeuds recoit donc un test de receveur */
144                 prepareTests(nbNodes, sender);
145
146                 for(recver = 1; recver < nbNodes; recver++) {
147                     if(recver != sender) {
148
149                         /* Envoi d'un test a l'envoyeur, lui indiquant de
                                communiquer avec le receveur courant */
150                         launchTests(sender, recver);
151
152                         /* Reception du resultat du test, directement dans la
                                matrice des resultats */
153                         receiveResults(&benchResults[sender][recver], sender);
154                     }
155                 }
156             }
157         }
158
159         /* Calcul des statistiques */
160         stats(benchResults, bissResults, &latencyStats, &flowStats, nbNodes,
                bissection);
```

```
161
162         /* Ecriture d'un fichier YAML si l'option -o est passee */
163         if(yaml)
164             toYAML(benchResults, bissResults, yamlFile, nbNodes, bissection);
165
166         /* Sortie en coordonnees pour un graphique gnuplot des debits selon des
                bissections */
167         if(gnuplot) {
168             toGnuplot(&flowStats, nbNodes);
169
170         /* Sinon matrice + stats */
171         } else {
172
173             /* Affichage d'un tableau/matrice non-parsable sur la sortie standard
                    */
174             displayTab(benchResults, bissResults, bissection, nbNodes);
175
176             /* Affichage des statistiques sur la sortie standard */
177             displayStats(benchResults, bissResults, &latencyStats, &flowStats,
                    nbNodes, bissection);
178         }
179
180     /* Si le noeud qui execute le programme n'est pas le MASTER (rank != 0), alors
            il sera charge de participer aux tests
181     qui lui enverra le MASTER, et de lui en renvoyer les resultats.
182     Dans le cas d'une bissection, chaque noeud n'aura qu'un seul role dans sa vie (
            envoyeur ou receveur), alors que dans le
183     cas de matrice, chacun des noeuds autant de fois envoyeur qu'il y a de noeud,
            et autant de fois receveur. A l'exclusion,
184     chaque fois, du rank 0, d'ou le -2 */
185     } else while(l++ < (bissection ? 1 : nbNodes*2-4)) {
186
187         sameBenchs = (Bench *) malloc(sizeof(Bench)*nbRetry);
188
189         if(sameBenchs == NULL) {
190             fprintf(stderr, "ERROR: Can't allocate memory.");
191             exit(1);
192         }
193
194         /* Si c'est une bissection, la fonction collective est utilise pour
                recevoir le test en meme tps que tout le monde */
195         if(bissection)
196             bissTransmitAllTests(bissTests, &myTest);
197
198         /* Sinon, le noeud est simplement en ecoute d'un test sur le rank 0 */
199         else
200             waitTests(&myTest);
201
202         /* Formatage du type MyResult qui sera renvoye, en renseignant le hostname
                du noeud courant, les deux joueurs de ce tests
203         et les valeurs du flow et debit initialisees a -1 */
204         formatTestsResult(&myResult, &myTest, rank);
205
206         switch(myTest.role) {
207
208             /* Le test recu du rank 0 designe le noeud temporairement comme
                    envoyeur */
209             case SENDER :
210
211                 /* Les tests avec le noeud receveur se repeteront autant de fois
                        que l'indication de precision
212                 nbRetry l'impose */
213                 for(i = 0; i < nbRetry; i++) {
214
215                     /* Si c'est une bissection, la fonction collective de lancement
                            des tests est rappellee a chaque fois.
216                     Ceci permet d'etre assure que tout le monde recommence bien son
                            test au meme moment. Sans cela, les couples
217                     qui auraient pris du retard sur le premier test se retrouveront
                            seuls dans les derniers tests, lorsque les
218                     plus rapides les auront tous finis. Il seront donc moins
                        ralentis pour ces derniers tests, qui fausseront
219                     leur moyenne. */
```

```
220                     if(bissection)
221                         bissLaunchAllTests();
222
223                     /* Envoi du mot vide pour la latence, reception du resultat,
                           envoi du mot de pktSize octets pour le debit,
224                     reception du resultat.
225                     Les differences de temps entre chaque envoi et reponse
                           permettent de calculer la latence et le debit, qui
226                     seront stockes dans le tableau des benchs de ce test, passe en
                           parametre en ecriture. */
227                     benchTests(&myTest, &sameBenchs[i], pktSize);
228                 }
229
230                 sumLatency = sumFlow = 0;
231
232                 /* Calcul des sommes pour etablir une moyenne de tous les resultats
                        du meme test */
233                 for(i = 0; i < nbRetry; i++) {
234                     sumLatency += sameBenchs[i].latency;
235                     sumFlow += sameBenchs[i].flow;
236                 }
237
238                 /* Calcul des moyennes et initialisation des valeurs du MyResult
                        qui sera renvoye au MASTER */
239                 myResult.result.latency = sumLatency / nbRetry;
240                 myResult.result.flow = sumFlow / nbRetry;
241
242                 /* Si ca n'est pas une bissection, renvoi direct des resultats au
                        MASTER */
243                 if(!bissection)
244                     sendResults(&myResult);
245
246             break;
247
248             /* Le role du desactive intervient dans un unique cas de figure : en
                    mode bissection, si le nombre de noeud, en l'enlevant le rank 0,
249             est impaire. Le noeud du rank le plus eleve recoit donc ce role, qui le
                     fera participer aux fonction collectives, mais qui ne sera pas
250             pris en compte. Tous les noeuds ne naissent pas libres et egaux... */
251             case DEACTIVATED :
252
253             /* Cas d'un receveur */
254             case RECVER :
255
256                 /* Le receveur recevra autant de fois que nbRetry l'impose, parce
                        que l'envoyeur enverra tout autant de fois */
257                 for(i = 0; i < nbRetry; i++) {
258
259                     /* Si c'est une bissection, la reception est bloquee tant qu'un
                             nouveau depart de synchro n'a pas ete donne
260                     par le MASTER */
261                     if(bissection)
262                         bissLaunchAllTests();
263
264                     /* Si on est pas dans le cas d'un exclu, reponse aux deux tests
                             successifs de l'envoyeur partenaire */
265                     if(myTest.role != DEACTIVATED)
266                         responsesToTests(&myTest, pktSize);
267                 }
268         }
269
270         /* Dans le cas d'une bissection, tous les resultats sont envoyes en meme
                temps au MASTER, a travers une fonction collective.
271         Les resultats des receveurs ou du desactive ne seront pas pris en compte.
                */
272         if(bissection)
273             bissTransmitAllResults(bissResults, &myResult);
274     }
275
276     //freee(buffer, bissResults, bissTests, benchResults, sameBenchs, nbNodes,
            nbRetry);
277
278     MPI_Finalize();
```

```
279
280     return 0;
281 }
282
283
284 /*********************
285  ***** FUNCTIONS *****
286  *********************/
287
288 /*
289  * Gestion des options du script
290  */
291 void initOptions(int argc, char** argv, int nbNodes, int rank, int* pktSize, int*
        nbRetry, int* bissection, int* randBiss, int* gnuplot, int* yaml, char*
        yamlFile) {
292     char opt, unit;
293
294     /* La taille par defaut du mot envoye pour les tests de debit est 1M */
295     *pktSize = 1024 * 1024;
296
297     /* Le nombre de fois par defaut qu'un test est repete pour ameliore la
            precision des resultats est 10 */
298     *nbRetry = 10;
299
300     /* Par defaut, la bissection (et a forciori la bissection aleatoire) ainsi que
            le yaml sont desactives */
301     *bissection = *randBiss = *gnuplot = *yaml = 0;
302
303     while((opt = getopt(argc, argv, "hs:p:bro:g")) != -1) {
304         switch(opt) {
305
306             /* Help */
307             case 'h' :
308                 if(rank == MASTER) {
309                     puts("\nOAR FLOW LATENCY TESTS");
310                     puts("----------------------");
311                     puts("\t-s <n>K   : Message size for flow tests exchanges, in
                            bytes (with K, M, or G suffix). Min 64K, default 1M.");
312                     puts("\t-p <n>    : Tests precision (repeats each test <n>
                            times and make averages). Default 10.");
313                     puts("\t-b        : Bisection (first node of the first half
                            with the first node of the seconde half, and so on).");
314                     puts("\t-rb, -r   : Bisection, with random pairs.");
315                     puts("\t-bg, -g   : Bisection, with gnuplot coordinates output.
                            ");
316                     puts("\t-o <file> : YAML output.\n");
317                     puts("\t-h        : This help.\n");
318                     puts("AUTHORS : <julien@vaubourg.com>\n          <sebastien.
                            badia@gmail.com>\n");
319                 }
320
321                 MPI_Finalize();
322                 exit(0);
323             break;
324
325             /* Taille des mots qui seront envoyes pour les tests de debit, en
                    octets et avec un suffix (K, M, G) */
326             case 's' :
327
328                 /* Recuperation de l'unite utilisee en recuperant le dernier
                        caractere de la valeur (nK, nM, ou nG), puis suppression de
                        celle-ci */
329                 unit = optarg[strlen(optarg) - 1];
330                 *(strchr(optarg, unit)) = '\0';
331                 *pktSize = atoi(optarg);
332
333                 /* En l'absence de break intermediaires, la taille du mot sera
                        multipliee par autant de fois qu'il faudra traverser une unite
334                 subalterne pour atteindre le break final. */
335                 switch(unit) {
336                     case 'G' :
337                         *pktSize *= 1024;
338                     case 'M' :
```

```
339                         *pktSize *= 1024;
340                     case 'K' :
341                         *pktSize *= 1024;
342                     break;
343
344                     default :
345                         if(rank == MASTER)
346                             fprintf(stderr, "ERROR: Unit -s unknown (K, M, or G).")
                                ;
347
348                         exit(1);
349                 }
350
351                 /* Un calcul de debit ne peut pas se faire avec un mot de moins de
                    64K (tests NWS) */
352                 if(*pktSize < 64*1024) {
353                     if(rank == MASTER)
354                         fprintf(stderr, "ERROR: For realistic flows results, the
                            message size defined by -s must be greater than 64KB (
                            NWS method).");
355
356                     exit(1);
357                 }
358             break;
359
360             /* Mode bissection : couples aleatoires si -r, en fonction de la
                moitiee de la liste des noeuds sinon */
361             case 'r' :
362                 *randBiss = 1;
363             case 'b' :
364                 *bissection = 1;
365             break;
366
367             /* Sortie pour un graphique gnuplot */
368             case 'g' :
369                 *gnuplot = 1;
370                 *bissection = 1;
371             break;
372
373             /* Sortie dans un fichier YAML en plus de la sortie matrice */
374             case 'o' :
375                 *yaml = 1;
376                 strncpy(yamlFile, optarg, 50);
377             break;
378
379             /* Les tests se feront autant de fois que l'indicateur de precision -p
                le dit, en prenant la moyenne des resultats de tous */
380             case 'p' :
381                 *nbRetry = atoi(optarg);
382
383                 if(*nbRetry < 0) {
384                     if(rank == MASTER)
385                         fprintf(stderr, "ERROR: The -p option must be positive.");
386
387                     exit(1);
388                 }
389             break;
390
391             /* Option inconnue ou mal renseignee */
392             case '?' :
393                 if(rank == MASTER) {
394                     if(optopt == 's' || optopt == 'r' || optopt == 'o')
395                         fprintf(stderr, "ERROR: The -%c option require an argument
                            .\n", optopt);
396                     else if(isprint(optopt))
397                         fprintf(stderr, "ERROR: The -%c option is unknown.\n",
                            optopt);
398                     else
399                         fprintf(stderr, "ERROR: The '\\x%x' character is unknown.\n
                            ", optopt);
400                 }
401             default:
402                 exit(1);
```

```
403             }
404         }
405
406         if(nbNodes < 3) {
407             if(rank == MASTER)
408                 fprintf(stderr, "ERROR : Tests requires at least 3 nodes (1 for
                        monitoring, at least 2 for exchanges).");
409
410             exit(1);
411         }
412     }
413
414     /*
415      * Creation d'un type BenchType pour MPI qui permettra de faire transiter des
            structures Bench d'un noeud a l'autre.
416      */
417     void createBenchType() {
418         MPI_Type_extent(MPI_INT, &extentType);
419
420         benchTypeDisp[0] = 0;
421         benchTypeDisp[1] = extentType;
422         benchTypeDisp[2] = extentType*2;
423
424         MPI_Type_extent(MPI_FLOAT, &extentType);
425
426         benchTypeDisp[3] = benchTypeDisp[2] + extentType;
427
428         MPI_Type_struct(4, benchTypeBlocks, benchTypeDisp, benchTypeTypes, &BenchType);
429         MPI_Type_commit(&BenchType);
430     }
431
432     /*
433      * Creation d'un type TestType pour MPI qui permettra de faire transiter des
            structures YourTest d'un noeud a l'autre.
434      */
435     void createTestType() {
436         MPI_Type_extent(MPI_INT, &extentType);
437
438         testTypeDisp[0] = 0;
439         testTypeDisp[1] = extentType;
440
441         MPI_Type_struct(2, testTypeBlocks, testTypeDisp, testTypeTypes, &TestType);
442         MPI_Type_commit(&TestType);
443     }
444
445     /*
446      * Creation d'un type ResultType pour MPI qui permettra de faire transiter des
            structures MyResult d'un noeud a l'autre.
447      */
448     void createResultType() {
449         MPI_Datatype resultTypeTypes[2] = { MPI_CHAR, BenchType };
450         MPI_Type_extent(MPI_CHAR, &extentType);
451
452         resultTypeDisp[0] = 0;
453         resultTypeDisp[1] = extentType*100;
454
455         MPI_Type_struct(2, resultTypeBlocks, resultTypeDisp, resultTypeTypes, &
                ResultType);
456         MPI_Type_commit(&ResultType);
457     }
458
459     /*
460      * Met en ecoute tous les autres noeuds que l'envoyeur designe, afin qu'ils soient
            prets a recevoir un test de celui-ci.
461      */
462     void prepareTests(int nbNodes, int sender) {
463         int i;
464         YourTest t;
465
466         for(i = 1; i < nbNodes; i++) {
467             if(i != sender) {
468                 t.role = RECVER;
469                 t.withRank = sender;
```

```
470
471                 MPI_Send(&t, 1, TestType, i, 0, MPI_COMM_WORLD);
472             }
473         }
474     }
475
476     /*
477      * Envoi de son test a l'envoyeur pour lui indiquer de communiquer avec un des
            receveurs pret a receptionner un mot
478      * de lui.
479      */
480     void launchTests(int sender, int recver) {
481         YourTest t;
482
483         t.role = SENDER;
484         t.withRank = recver;
485
486         MPI_Send(&t, 1, TestType, sender, 0, MPI_COMM_WORLD);
487     }
488
489     /*
490      * Par defaut, tous les noeuds attendent un test du MASTER.
491      */
492     void waitTests(YourTest* t) {
493         MPI_Recv(t, 1, TestType, MASTER, 0, MPI_COMM_WORLD, &status);
494     }
495
496     /*
497      * Envoi du resultat MyResult au MASTER, de la part de l'envoyeur.
498      */
499     void sendResults(MyResult* r) {
500         MPI_Send(r, 1, ResultType, MASTER, 0, MPI_COMM_WORLD);
501     }
502
503     /*
504      * Reception du resultat MyResult de l'envoyeur qui vient de realiser son test (
            pour le rank 0).
505      */
506     void receiveResults(MyResult* r, int sender) {
507         MPI_Recv(r, 1, ResultType, sender, 0, MPI_COMM_WORLD, &status);
508     }
509
510     /* Formatage du MyResult qui sera renvoye au MASTER */
511     void formatTestsResult(MyResult* r, YourTest* t, int rank) {
512         int sizeHostname;
513         char* sep;
514
515         /* Les deux joueurs sont renseignes, et la latence est mise a -1 : si le test n
                'est
516         jamais utilise, la latence restera ainsi, et pourra alors etre un indicateur de
                la non
517         pertinence du resultat. */
518         r->result.sender = rank;
519         r->result.recver = t->withRank;
520         r->result.latency = r->result.flow = -1;
521
522         /* Renseignement du nom du noeud courant */
523         MPI_Get_processor_name(r->myHostname, &sizeHostname);
524
525         /* Reduction du nom du noeud a sa premiere partie (on vire .site.grid5000.fr)
                */
526         sep = strchr(r->myHostname, '.');
527         *sep = '\0';
528     }
529
530     /*
531      * Tests de debit/latence de l'envoyeur vers le receveur.
532      */
533     void benchTests(YourTest* t, Bench* r, int pktSize) {
534         double start, stop;
535
536         /* Un mot vide (4 octets) est envoye au receveur, qui repondra immediatement un
                mot de la meme nature.
```

```
537      Le temps est compte, de l'envoi du mot au receveur jusqu'a la reception de sa
             reponse. */
538      start = MPI_Wtime();
539      MPI_Send(buffer, 0, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD);
540      MPI_Recv(buffer, 0, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD, &status);
541      stop = MPI_Wtime();
542
543      /* La latence est calculee en fonction du temps mis par le mot pour arriver au
             destinataire (division par 2
544      pour eliminer le tps de reponse qui est cense etre identique.
545      Passage de seconde a microseconde en multiplisant par un million. */
546      r->latency = ((stop-start) / 2) * 1e6;
547
548      /* Un mot plus ou moins consequent (option -s) est envoye au receveur. Celui-ci
              renvoyant un mot vide.
549      Le temps est egalement compte, de l'envoi jusqu'a la reception. */
550      start = MPI_Wtime();
551      MPI_Send(buffer, pktSize, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD);
552      MPI_Recv(buffer, 0, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD, &status);
553      stop = MPI_Wtime();
554
555      /* La difference de temps est prise en compte. On lui soustraie deux fois la
             latence - en seconde grace a la
556      division - d'un mot vide (soit le tps que met le tuyau a faire transiter les
             donnees, quelque soit la taille des
557      donnees). Enfin, on divise le nombre d'octets qui ont transites avec ce
             resultat. On divise le tout par 1024 au
558      carre pour avoir des Mo/s au lieu de o/s. Cette facon de proceder releve de l'
             approche NWS : http://nws.cs.ucsb.ed */
559      r->flow = pktSize / ((stop-start) - (2*r->latency/1e6)) / pow(1024, 2);
560  }
561
562  /*
563   * Reponses automatiques aux envoi du noeud qui joue le role d'envoyeur.
564   */
565  void responsesToTests(YourTest* t, int pktSize) {
566      MPI_Recv(buffer, 0, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD, &status);
567      MPI_Send(buffer, 0, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD);
568
569      MPI_Recv(buffer, pktSize, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD, &status);
570      MPI_Send(buffer, 0, MPI_BYTE, t->withRank, 1, MPI_COMM_WORLD);
571  }
572
573  /*
574   * Creation de tous les tests qui seront repartis entre tous les noeuds, pour le
          mode bissection, sans les envoyer et en les
575   * stockant dans un tableau.
576   */
577  void bissPrepareAllTests(YourTest* bissTests, int nbNodes) {
578      int m, i;
579      YourTest t;
580
581      /* Le rank 0 ne participe pas */
582      nbNodes--;
583
584      /* Si il y a un nb impaire de noeud, on ignore le dernier, en le faisant quand
             meme participer
585      aux fonctions collectives*/
586      if(nbNodes % 2) {
587          bissTests[nbNodes].role = DEACTIVATED;
588          bissTests[nbNodes].withRank = -1;
589          nbNodes--;
590      }
591
592      m = nbNodes / 2;
593
594      /* Pour chaque paire */
595      for(i = 1; i <= m; i++) {
596
597          /* Le receveur de la paire est le n ieme de la seconde moitie */
598          bissTests[m+i].role = RECVER;
599          bissTests[m+i].withRank = i;
600
```

```
601             /* L'envoyeur est le n ieme de la premiere moitie */
602             bissTests[i].role = SENDER;
603             bissTests[i].withRank = m+i;
604         }
605     }
606
607     /*
608      * Creations des tests pour la bissection, en creant les paires de noeuds de facon
            aleatoire (sans envoyer les tests,
609      * et en les stockant dans un tableau.
610      */
611     void bissPrepareAllRandTests(YourTest* bissTests, int nbNodes) {
612         int i, r, randRank, ranks[2], iLeft, *ranksLeft, nbLeft;
613         YourTest t;
614
615         /* Le rank 0 ne participe pas */
616         nbNodes--;
617
618         /* Si il y a un nb impaire de noeud, on ignore le dernier, en le faisant quand
                meme participer
619         aux fonctions collectives*/
620         if(nbNodes % 2) {
621             bissTests[nbNodes].role = DEACTIVATED;
622             bissTests[nbNodes].withRank = -1;
623             nbNodes--;
624         }
625
626         /* Nombre et liste des noeuds qui n'ont pas encore de test attribue */
627         nbLeft = nbNodes;
628         ranksLeft = (int*) malloc(sizeof(int) * nbLeft);
629
630         if(ranksLeft == NULL) {
631             fprintf(stderr, "ERROR: Can't allocate memory.");
632             exit(1);
633         }
634
635         /* Initialisation des noeuds : avec la valeur 1, chacun est encore vaquant */
636         for(i = 0; i < nbLeft; ranksLeft[i++] = 1);
637
638         /* Pour tous les noeuds vaquants restants */
639         while(nbLeft != 0) {
640
641             /* Extraction de deux noeuds choisis aleatoirement parmis les noeuds encore
                    disponibles
642             Premier tour pour l'envoyeur, second tour pour le receveur */
643             for(i = 0; i < 2; i++) {
644                 srand(time(NULL));
645
646                 /* Tirage d'un nombre aleatoire qui definira le rank du noeud choisi,
                        parmis les ranks restants.
647                 Ex: si 3 est tire, le rank selectionne sera le 3ieme qui n'a pas encore
                        ete utilise */
648                 randRank = rand() % (nbLeft-1);
649
650                 r = -1;
651                 iLeft = 0;
652                 ranks[i] = -1;
653
654                 /* Pour tous les ranks jusqu'a ce que le n ieme rank encore vaquant
                        soit atteint */
655                 while(ranks[i] == -1) {
656
657                     /* Si le rank en cours est encore vaquant */
658                     if(ranksLeft[++r] != -1) {
659
660                         /* Si le rank en cours correspond au rank du tirage aleatoire,
                                selection de ce rank (+1, puisque le rank 0 a ete supprime)
                                */
661                         if(iLeft == randRank)
662                             ranks[i] = r + 1;
663
664                         /*  Sinon incrementation du nb des ranks encore vaquants deja
                                rencontres */
```

```
665                         iLeft++;
666                     }
667                 }
668
669                 /* Ce rank ne pourra plus etre selectionne */
670                 ranksLeft[r] = -1;
671             }
672
673             /* Deux ranks en moins a attribuer */
674             nbLeft -= 2;
675
676             /* Creation du test du receveur, qui attendra alors un message de son
                    camarade de jeu */
677             bissTests[ranks[1]].role = RECVER;
678             bissTests[ranks[1]].withRank = ranks[0];
679
680             /* Creation du test de l'envoyeur */
681             bissTests[ranks[0]].role = SENDER;
682             bissTests[ranks[0]].withRank = ranks[1];
683         }
684     }
685
686     /*
687      * Fonction collective d'envoi du test associe a chaque rank, depuis le MASTER.
688      */
689     void bissTransmitAllTests(YourTest* bissTests, YourTest* t) {
690         MPI_Scatter(bissTests, 1, TestType, t, 1, TestType, MASTER, MPI_COMM_WORLD);
691     }
692
693     /*
694      * Fonction collective d'envoi d'un broadcast vide, permettant de lancer un depart
            synchro des tests de bissections.
695      */
696     void bissLaunchAllTests() {
697         MPI_Bcast(buffer, 0, MPI_BYTE, MASTER, MPI_COMM_WORLD);
698     }
699
700     /*
701      * Fonction collectice d'envoi des resultats de la part de chaque rank vers le
            MASTER.
702      */
703     void bissTransmitAllResults(MyResult* bissResults, MyResult* r) {
704         MPI_Gather(r, 1, ResultType, bissResults, 1, ResultType, MASTER, MPI_COMM_WORLD
                );
705     }
706
707     /* Fonction permettant la conversion numero de rank vers Hostname. */
708     char* rankToHostname(MyResult** r, MyResult* rBiss, int rank, int bissection) {
709         if(bissection)
710             return rBiss[rank].myHostname;
711         else
712             return r[rank][rank == 1 ? 2 : 1].myHostname;
713     }
714
715     /*
716      * Affichage des resultats sous forme de tableau texte non-parsable.
717      */
718     void displayTab(MyResult** r, MyResult* rBiss, int bissection, int nbNodes) {
719         int x, y, i;
720
721         /* Affichage des resultats de la bissections sous forme d'un tableau simple
                dont la premier colonne indique
722         l'envoyeur et la seconde le receveur avec la latence et le debit calculees */
723         if(bissection) {
724
725             /* Pour chaque envoyeur */
726             for(i = 1; i < nbNodes; i++) {
727
728                 /* La latence differente de -1 signifie que le MyResult a ete exploite
                        et n'est pas le retour d'un
729                 RECVER ou d'un DEACTIVATED */
730                 if(rBiss[i].result.latency != -1) {
731                     puts("+--------------------+----------------------+");
```

```
732                 printf("| From %-15s", rankToHostname(r, rBiss, i, bissection));
733                 printf("| To %-17s |\n", rankToHostname(r, rBiss, rBiss[i].result.
                        recver, bissection));
734                 printf("|                          ");
735                 printf("| %17.3f us |\n", rBiss[i].result.latency);
736                 printf("|                          ");
737                 printf("| %15.3f Mo/s |\n", rBiss[i].result.flow);
738             }
739         }
740 
741         puts("+----------------------+----------------------+");
742 
743     /* Affichage des resultats sous forme d'une matrice equilibree de tous les
        noeuds, avec la debit et la latence pour chaque
744     paire de noeud possible, dans les deux sens */
745     } else {
746 
747         /* Premiere ligne de tirets */
748         printf("                         ");
749         for(x = 1; x < nbNodes; printf("+----------------------"), x++);
750         printf("+\n                          ");
751 
752         /* Lignes des entetes de colonnes (receveurs) */
753         for(x = 1; x < nbNodes; printf("| To %-17s ", rankToHostname(r, rBiss, x++,
                bissection)));
754         printf("|\n");
755 
756         /* Ligne de tirets de separation */
757         for(x = 0; x < nbNodes; printf("+----------------------"), x++);
758         puts("+");
759 
760         /* Pour chaque ligne/envoyeur */
761         for(y = 1; y < nbNodes; y++) {
762 
763             /* Entete */
764             printf("| From %-15s ", r[y][y == 1 ? 2 : 1].myHostname);
765 
766             /* Latence, ou suite de tirets si on est l'envoyeur correspond au
                    receveur */
767             for(x = 1; x < nbNodes; x++) {
768                 (x == y) ?
769                     printf("|----------------------") :
770                     printf("| %17.3f us ", r[y][x].result.latency);
771             }
772 
773             printf("|\n|                          ");
774 
775             /* Debit, ou suite de tirets si on est l'envoyeur correspond au
                    receveur */
776             for(x = 1; x < nbNodes; x++) {
777                 (x == y) ?
778                     printf("|----------------------") :
779                     printf("| %15.3f Mo/s ", r[y][x].result.flow);
780             }
781 
782             /* Fermeture de ligne */
783             puts("|");
784             for(x = 1; x < nbNodes+1; printf("+----------------------"), x++);
785             puts("+");
786         }
787     }
788 }
789 /*
790  * Affichage des statistiques en relation avec la matrice ou la bissection sous
        forme de texte non-parsable.
791  * Latence min et max ainsi que debit min et max.
792  * Ainsi que les sommes et les moyennes.
793  */
794 void displayStats(MyResult** r, MyResult* rBiss, StatsResult* latencyStats,
        StatsResult* flowStats, int nbNodes, int bissection) {
795 
796     puts("\nLatency :");
797 
```

```
798     /* Latence Maximum et affichage de la paire de noeuds correspondante, en
            hostname */
799     printf(
800         "Max : %.3f us \tFrom %s to %s\n",
801         latencyStats->max->latency,
802         rankToHostname(r, rBiss, latencyStats->max->sender, bissection),
803         rankToHostname(r, rBiss, latencyStats->max->recver, bissection)
804     );
805
806     /* Latence Minimum et affichage de la paire de noeuds correspondante, en
            hostname */
807         printf(
808         "Min : %.3f us \tFrom %s to %s\n",
809         latencyStats->min->latency,
810         rankToHostname(r, rBiss, latencyStats->min->sender, bissection),
811         rankToHostname(r, rBiss, latencyStats->min->recver, bissection)
812     );
813
814     /* Somme des latences et moyenne */
815     printf("Sum : %.3f us\n", latencyStats->sum);
816     printf("Avg : %.3f us\n", latencyStats->avg);
817
818         puts("\nFlow :");
819
820     /* Debit Maximum et affichage de la paire de noeuds correspondante, en hostname
            */
821         printf(
822         "Max : %.3f Mo/s \tFrom %s to %s\n",
823         flowStats->max->flow,
824         rankToHostname(r, rBiss, flowStats->max->sender, bissection),
825         rankToHostname(r, rBiss, flowStats->max->recver, bissection)
826     );
827
828     /* Debit Minimum et affichage de la paire de noeuds correspondante, en hostname
            */
829         printf(
830         "Min : %.3f Mo/s \tFrom %s to %s\n",
831         flowStats->min->flow,
832         rankToHostname(r, rBiss, flowStats->min->sender, bissection),
833         rankToHostname(r, rBiss, flowStats->min->recver, bissection)
834     );
835
836     /* Somme des debits et moyenne */
837     printf("Sum : %.3f Mo/s\n", flowStats->sum);
838         printf("Avg : %.3f Mo/s\n", flowStats->avg);
839 }
840
841 /*
842  * Ecriture en YAML dans un fichier des resultats.
843  */
844 void toYAML(MyResult** r, MyResult* rBiss, char* yamlFile, int nbNodes, int
        bissection) {
845     FILE* yaml;
846     int x, y, i;
847
848     yaml = fopen(yamlFile, "w");
849
850     if(yaml == NULL) {
851         fprintf(stderr, "ERROR: Can't write the yaml file.");
852         return;
853     }
854
855     /* Export du tableau des resultats (meme structure que pour la matrice) */
856     if(bissection) {
857
858         /* Pour chaque envoyeur */
859         for(y = 1; y < nbNodes; y++) {
860
861             /* Resultat d'un envoyeur */
862             if(rBiss[y].result.latency != -1) {
863                 fprintf(yaml, "%s\n", rankToHostname(r, rBiss, y, bissection));
864                 fprintf(yaml, "  %s\n", rankToHostname(r, rBiss, rBiss[y].result.
                        recver, bissection));
```

```
865                 fprintf(yaml, "    latency ; %.3f\n", rBiss[y].result.latency);
866                 fprintf(yaml, "    flow : %.3f\n", rBiss[y].result.flow);
867             }
868         }
869 
870     /* Export de la matrice des resultats (3 niveaux : envoyeur => receveur =>
        debit/latence) */
871     } else {
872 
873         /* Pour chaque envoyeur */
874         for(y = 1; y < nbNodes; y++) {
875             fprintf(yaml, "%s :\n", rankToHostname(r, rBiss, y, bissection));
876 
877             /* Pour chaque receveur */
878             for(x = 1; x < nbNodes; x++) {
879                 if(y != x) {
880                     fprintf(yaml, "  %s :\n", rankToHostname(r, rBiss, x,
                        bissection));
881                     fprintf(yaml, "    latency : %.3f\n", r[y][x].result.latency);
882                     fprintf(yaml, "    flow : %.3f\n", r[y][x].result.flow);
883                 }
884             }
885         }
886     }
887 
888     fclose(yaml);
889 }
890 
891 /*
892  * Exporte la somme des debits constates sous forme de coordonnees (x: nb noeuds, y
        : somme).
893  * Sert pour la construction d'un graphique gnuplot du total des debits de
        bissections testees avec des nombres de noeuds
894  * variables, et dans le cadre d'un script plus global.
895  */
896 void toGnuplot(StatsResult* flowStats, int nbNodes) {
897     printf("%d\t%.3f\n", nbNodes, flowStats->sum);
898 }
899 
900 /*
901  * Fonction de calcul des statistiques.
902  */
903 void stats(MyResult** r, MyResult* rBiss, StatsResult* latencyStats, StatsResult*
        flowStats, int nbNodes, int bissection) {
904     int i, j;
905     Bench initLatencyMin, initLatencyMax, initFlowMin, initFlowMax;
906 
907     /* Initialisation de la structure benchsStatsBounds */
908     latencyStats->min = &initLatencyMin;
909     latencyStats->min->latency = 99999999.99;
910 
911     latencyStats->max = &initLatencyMax;
912     latencyStats->max->latency = -1;
913 
914     flowStats->min = &initFlowMin;
915     flowStats->min->flow = 99999999.99;
916 
917     flowStats->max = &initFlowMax;
918     flowStats->max->flow = -1;
919 
920     /* Initialisation des sommes */
921     latencyStats->sum = flowStats->sum = 0;
922 
923     if(bissection) {
924         for (i = 1; i < nbNodes; i++) {
925 
926             /* Si la latence est encore en etat d'initialisation on arrete */
927             if(rBiss[i].result.latency != -1) {
928 
929                 /* Calcul de la Latence Minimum et attribution de l'adresse
                    correspondante */
930                 if (rBiss[i].result.latency < (latencyStats->min->latency)) {
931                     latencyStats->min = &(rBiss[i].result);
```

```
932                     }
933
934                     /* Calcul de la Latence Maximum et attribution de l'adresse
                           correspondante */
935                     if (rBiss[i].result.latency > (latencyStats->max->latency)) {
936                         latencyStats->max = &(rBiss[i].result);
937                     }
938
939                     /* Calcul du debit Minimum et attribution de l'adresse
                           correspondante */
940                     if (rBiss[i].result.flow < (flowStats->min->flow)) {
941                         flowStats->min = &(rBiss[i].result);
942                     }
943
944                     /* Calcul du debit Maximum et attribution de l'adresse
                           correspondante */
945                     if (rBiss[i].result.flow > (flowStats->max->flow)) {
946                         flowStats->max = &(rBiss[i].result);
947                     }
948
949                     /* Calcul de la somme des debits */
950                     flowStats->sum += rBiss[i].result.flow;
951
952                     /* Calcul de la somme des latence */
953                     latencyStats->sum += rBiss[i].result.latency;
954                 }
955             }
956
957             /* Calculs des Moyennes */
958
959             /* Debit */
960             flowStats->avg = flowStats->sum / ((nbNodes-1)/2);
961
962             /* Latence */
963             latencyStats->avg = latencyStats->sum / ((nbNodes-1)/2);
964
965         } else {
966
967             /* Double boucle afin de parcourir l'ensemble de la matrice */
968             for (i = 1; i < nbNodes; i++) {
969                 for (j = 1; j < nbNodes; ++j) {
970
971                     /* On evite le cas particulier ou le rank est egal (case vide) */
972                     if(i != j) {
973
974                         /* Calcul de la Latence Minimum et attribution de l'adresse
                               correspondante */
975                         if (r[i][j].result.latency < (latencyStats->min->latency)) {
976                             latencyStats->min = &(r[i][j].result);
977                         }
978
979                         /* Calcul de la Latence Maximum et attribution de l'adresse
                               correspondante */
980                         if (r[i][j].result.latency > (latencyStats->max->latency)) {
981                             latencyStats->max = &(r[i][j].result);
982                         }
983
984                         /* Calcul du debit Minimum et attribution de l'adresse
                               correspondante */
985                         if (r[i][j].result.flow < (flowStats->min->flow)) {
986                             flowStats->min = &(r[i][j].result);
987                         }
988
989                         /* Calcul du debit Maximum et attribution de l'adresse
                               correspondante */
990                         if (r[i][j].result.flow > (flowStats->max->flow)) {
991                             flowStats->max = &(r[i][j].result);
992                         }
993
994                         /* Calcul de la somme des debits */
995                         flowStats->sum += r[i][j].result.flow;
996
997                         /* Calcul de la somme des latence */
```

```
998                         latencyStats->sum += r[i][j].result.latency;
999                     }
1000                }
1001            }
1002
1003            /* Calcul des Moyennes et enregistrement */
1004
1005            /* Debit */
1006            flowStats->avg = flowStats->sum / (pow((nbNodes-1),2)-(nbNodes-1));
1007
1008            /* Latence */
1009            latencyStats->avg = latencyStats->sum / (pow((nbNodes-1),2)-(nbNodes-1));
1010        }
1011    }
1012
1013    /*
1014     * Liberation de la memoire pour les allocations faites manuellement.
1015     */
1016    void freee(int* buffer, MyResult* bissResults, YourTest* bissTests, MyResult**
        benchResults, Bench* sameBenchs, int nbNodes, int nbRetry) {
1017        int i;
1018
1019        free(buffer);
1020        free(bissResults);
1021        free(bissTests);
1022        free(sameBenchs);
1023
1024        for(i = 0; i < nbNodes; free(benchResults[i++]));
1025        free(benchResults);
1026    }
```

6 Librairie Latence et Débit

```
1   #ifndef LATENCY_FLOW_TESTS
2   #define LATENCY_FLOW_TESTS
3
4   #define DEACTIVATED -1
5   #define RECVER 0
6   #define SENDER 1
7   #define MASTER 0
8
9   typedef struct {
10      int sender, recver;
11      float latency, flow;
12  } Bench;
13
14  typedef struct {
15      int role, withRank;
16  } YourTest;
17
18  typedef struct {
19      char myHostname[100];
20      Bench result;
21  } MyResult;
22
23  typedef struct {
24      Bench *min, *max;
25      float sum, avg;
26  } StatsResult;
27
28  MPI_Datatype BenchType, TestType, ResultType;
29  MPI_Datatype benchTypeTypes[4] = { MPI_INT, MPI_INT, MPI_FLOAT, MPI_FLOAT };
30  MPI_Datatype testTypeTypes[2] = { MPI_INT, MPI_INT };
31  MPI_Aint benchTypeDisp[4], testTypeDisp[2], resultTypeDisp[2], extentType;
32  MPI_Status status;
33
34  int benchTypeBlocks[4] = { 1, 1, 1, 1 };
35  int testTypeBlocks[2] = { 1, 1 };
36  int resultTypeBlocks[2] = { 100, 1 };
37  int* buffer;
38
39  void initOptions(int argc, char** argv, int nbNodes, int rank, int* pktSize, int*
```

```
        nbRetry, int* bissection, int* randBiss, int* gnuplot, int* yaml, char*
        yamlFile);
40
41  void createBenchType();
42  void createTestType();
43  void createResultType();
44
45  void prepareTests(int nbNodes, int sender);
46  void launchTests(int sender, int recver);
47  void waitTests(YourTest* t);
48  void sendResults(MyResult* r);
49  void receiveResults(MyResult* r, int sender);
50
51  void formatTestsResult(MyResult* r, YourTest* t, int rank);
52  void benchTests(YourTest* t, Bench* r, int pktSize);
53  void responsesToTests(YourTest* t, int pktSize);
54
55  void bissPrepareAllTests(YourTest* bissTests, int nbNodes);
56  void bissPrepareAllRandTests(YourTest* bissTests, int nbNodes);
57  void bissTransmitAllTests(YourTest* bissTests, YourTest* t);
58  void bissLaunchAllTests();
59  void bissTransmitAllResults(MyResult* bissResults, MyResult* r);
60
61  char* rankToHostname(MyResult** r, MyResult* rBiss, int rank, int bissection);
62
63  void displayTab(MyResult** r, MyResult* rBiss, int bissection, int nbNodes);
64  void toYAML(MyResult** r, MyResult* rBiss, char* yamlFile, int nbNodes, int
        bissection);
65  void toGnuplot(StatsResult* flowStats, int nbNodes);
66
67  void stats(MyResult** r, MyResult* rBiss, StatsResult* latencyStats, StatsResult*
        flowStats, int nbNodes, int bissection);
68  void displayStats(MyResult** r, MyResult* rBiss, StatsResult* latencyStats,
        StatsResult* flowStats, int nbNodes, int bissection);
69
70  void freee(int* buffer, MyResult* bissResults, YourTest* bissTests, MyResult**
        benchResults, Bench* sameBenchs, int nbNodes, int nbRetry);
71
72  #endif
```

7 Script de calcul du débit total en fonction du nombre de nœuds

```
1  #!/bin/bash
2
3  if [[ -z "$OAR_NODEFILE" ]]; then
4      echo "ERROR : You must have a nodes reservation (oarsub, on a single cluster)."
           >&2
5      exit 1
6  fi
7
8  if [[ -z $1 ]]; then
9      echo "Usage: ./flowsSumsBis.sh <step>" >&2
10     exit 1
11 fi
12
13 STEP=$1
14 MACHINES=/tmp/${USER}_machines
15 PLOTFILE=flowsSumsBis.dat
16 i=3
17
18 head -n1 $OAR_NODEFILE > $MACHINES
19 sort -u $OAR_NODEFILE >> $MACHINES
20 NB=$(cat $MACHINES | wc -l)
21 :> $PLOTFILE
22
23 if [[ $NB -lt 3 ]]; then
24     echo "ERROR : Tests requires at least 3 nodes (1 for monitoring, at least 2 for
           exchanges)." >&2
25     exit 1
```

```
26 fi
27
28 while [[ $i -le $NB ]]; do
29     echo "Bisection : calculating the flow sum with $i nodes..."
30     mpirun -np $i --mca plm_rsh_agent oarsh -machinefile $MACHINES ./
           latency_flow_tests -g 2> /dev/null >> $PLOTFILE
31     i=$(( i + STEP ))
32 done
33
34 rm $MACHINES
35 exit 0
```

8 Script gnuplot pour l'exploitation des résultats du script *bash*

```
1 set terminal postscript eps color "Sans-serif" 16
2 set output 'latencyFlows.eps'
3 set key right bottom
4 set xlabel "Nombre de noeuds dans la bissection"
5 set ylabel "Debit en Mo/s"
6 set grid
7
8 plot 'Result/gdx/latencyFlows.dat' using 1:2 title 'gdx' with linespoints
9 quit
```

9 Script Ruby d'export Yaml vers Html

```
1  #!/usr/bin/ruby -w
2  #
3  # YAML TO HTML (LATENCY FLOW TESTS)
4  #   With great colors !
5  #
6  # OPTIONS : Voir -h
7  #
8  # AUTEURS : <julien@vaubourg.com>
9  #           <seb@sebian.fr> <badia.seb@gmail.com>
10 #
11 # 2010, pour Grid5000
12 #
13
14 # Ce script a pour but de transformer le fichier d'export yaml du programme '
       latency_flow_test'
15 # en un tableau html, avec des couleurs. (faisant ressortir les min/max ainsi que
       les quartiles)
16
17 # Utilise la classe yaml, il sera peut etre necessaire de l'installer
18 require 'yaml'
19 require 'getoptlong'
20
21     # Les options -i pour input et -o pour output sont indispensables.
22     opts = GetoptLong.new(
23       [ '--help', '-h', GetoptLong::NO_ARGUMENT ],
24       [ '--yaml', '-i', GetoptLong::REQUIRED_ARGUMENT ],
25       [ '--html', '-o', GetoptLong::REQUIRED_ARGUMENT ]
26     )
27
28 fileyaml = html = ''
29
30 opts.each do |opt, arg|
31   case opt
32         when '--help'
33         puts("\nYAML TO HTML")
34         puts("-----------------------------------")
35         puts("This script allows the conversion of YAML file")
36         puts("(output file of latency_flow_test) into an HTML table.")
37         puts("An HTML table was easily viewable on a website.\n")
38         puts("The color code allows to visualize at once the most low knots,")
39         puts("and those them more successful")
```

```
40          puts("---------------------------------")
41          puts("Usage :\n")
42          puts("\t toYaml.rb -i <yaml file> -o <html file>")
43          puts("\nOptions :\n")
44          puts("\t-i <file> : Yaml input.")
45          puts("\t-o <file> : Html output.\n")
46          puts("\t-h        : This help.\n")
47          puts("\nLegend of HTML Table :\n")
48          puts("\tRed background : \tlowest latency/flow")
49          puts("\tGreen background : \thigher latency/flow")
50          puts("\tGreen write : \t\tFirst quartile")
51          puts("\tRed write : \t\tLast quartile\n")
52          puts("\nAuthors :\n\t<julien@vaubourg.com>\n\t<sebastien.badia@gmail.com>\t
                <seb@sebian.fr>\n")
53          puts("\nAsrall 2010 for Grid5000")
54        exit!(1)
55
56          when '--yaml'
57          fileyaml = arg
58
59          when '--html'
60                  html = arg
61
62    end
63  end
64
65  # Verification d'usage, les options ont elles ete passees
66  if fileyaml.empty? || html.empty?  then
67          puts "Veuillez preciser des arguments (fichier d'import et d'export)"
68          puts "Consultez l'aide (Option -h)"
69          exit!(1)
70  end
71
72  # Parse directement le fichier yaml, en reconnait l'arborescence, et fait un
        tableau avec celle-ci.
73  benchResults = YAML.load_file(fileyaml)
74
75  # Creation des tableaux de initialisation de l'ecc, ecc pour effectif cumul
        croissant
76  flows = []
77  latencys = []
78  eccFlow = eccLatency = sumLatency = sumFlow = 0
79
80  benchResults.each do |sender, recvers|
81      recvers.each do |recver, results|
82          # manque de pointeurs...
83          latencys << {
84              :sender => sender,
85              :recver => recver,
86              :latency => results['latency']
87          }
88
89          flows << {
90              :sender => sender,
91              :recver => recver,
92              :flow => results['flow']
93          }
94
95          sumLatency += results['latency']
96          sumFlow += results['flow']
97      end
98  end
99
100 latencys.sort! { |a, b| a[:latency] <=> b[:latency] }
101 flows.sort! { |a, b| a[:flow] <=> b[:flow] }
102
103 # Cumul des latences et des debits
104 (0...flows.size).each do |i|
105     eccLatency = latencys[i][:ecc] = latencys[i][:latency] + eccLatency
106     eccFlow = flows[i][:ecc] = flows[i][:flow] + eccFlow
107 end
108
109 # Calcul des quartiles
```

```
110 q1Latency = latencys.last[:ecc] / 4
111 q3Latency = q1Latency * 3
112 q1Flow = flows.last[:ecc] / 4
113 q3Flow = q1Flow * 3
114
115 # On cree un varaiable 'matrix' dans laquelle on concatenera tout le html genere
116 matrix = "<tr><th></th><th class=\"bot\">#{ benchResults.keys.join('</th><th class=
        "bot">') }</th><th class=\"bot\"></th></tr>"
117 line = 0
118
119 benchResults.each do |sender, recvers|
120     matrix += '<tr><th class="right' + (line == benchResults.size - 1 ? " bot" : ""
            ) + '" rowspan="2">' + sender + '</th>'
121     # On rempli la matrix avec tout les debits
122     column = 0
123     recvers.each do |recver, results|
124         matrix += '<td></td>' if line == column
125         column += 1
126
127         matrix += <<-HTML
128         <td class="flow#{
129             case results['flow']
130                 when flows.first[:flow]
131                     " min"
132                 when flows.last[:flow]
133                     " max"
134                 else
135                     case flows[flows.index { |x| x[:sender] == sender && x[:recver]
                            == recver }][:ecc]
136                         when 0..q1Flow
137                             " low"
138                         when q3Flow..flows.last[:ecc]
139                             " high"
140                     end
141             end
142         }">#{results['flow']}</td>
143 HTML
144     end
145
146     matrix += (line == benchResults.size - 1 ? "<td></td>" : "") + '<td class="
            unite flow">MB/s</td></tr><tr>'
147
148     column = 0
149     recvers.each do |recver, results|
150         matrix += '<td class="empty"></td>' if line == column
151         column += 1
152         # Mise en place des latences dans la matrice
153         matrix += <<-HTML
154         <td class="latency#{
155             case results['latency']
156                 when latencys.first[:latency]
157                     " min"
158                 when latencys.last[:latency]
159                     " max"
160                 else
161                     case latencys[latencys.index { |x| x[:sender] == sender && x[:
                            recver] == recver }][:ecc]
162                         when 0..q1Latency
163                             " low"
164                         when q3Latency..latencys.last[:ecc]
165                             " high"
166                     end
167             end
168         }">#{results['latency']}</td>
169 HTML
170     end
171
172     matrix += (line == benchResults.size - 1 ? '<td class="empty"></td>' : "") + '<
            td class="unite latency">&micro;s</td></tr>'
173     line += 1
174 end
175
176 # Ecriture du fichier de sortie html, avec la CSS et la matrix prealablement
```

```
        remplie
177  File.open(html,'w') do |fo|
178   fo << <<-HTML
179      <!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN" "http://www.w3.org/TR/
           xhtml1/DTD/xhtml1-strict.dtd">
180      <html xmlns="http://www.w3.org/1999/xhtml" xml:lang="en" lang="en">
181      <head>
182      <title>Flow Latency Tests - Matrix</title>
183      <meta http-equiv="Content-Type" content="text/html; charset=UTF-8" />
184      <style type="text/css">
185      <!--
186          body {
187              background-color: #EEE;
188              font-family: sans-serif;
189          }
190
191          h1, h2 {
192              text-align: center;
193              font-size: 30px;
194              margin: 5px;
195          }
196
197          h2 { font-size: 20px}
198
199          table {
200              border: 1px solid #000;
201              border-bottom: 0;
202              text-align: center;
203              margin: 30px auto;
204          }
205
206          th {
207              background-color: #BBB;
208              padding: 5px;
209          }
210
211          th.bot { border-bottom: 1px solid #000 }
212          th.right { border-right: 1px solid #000 }
213
214          td {
215              background-color: #AAA;
216              padding: 10px;
217          }
218
219          td.latency {
220              background-color: #EEE;
221              border-bottom: 1px solid #000;
222          }
223
224          td.flow { background-color: #CCC }
225
226          td.min, td.max {
227              background-color: red;
228              font-weight: bold;
229              color: white;
230          }
231
232          td.max { background-color: green }
233
234          td.high { color: green }
235          td.low { color: red }
236
237          td.empty { border-bottom: 1px solid #000 }
238          td.unite { font-weight: bold }
239
240          address {
241              text-align: center;
242              font-size: 10px;
243          }
244      -->
245      </style>
246      </head>
247
```

```
248       <body>
249       <h1>Latency flow tests</h1>
250       <h2>(with nice colors)</h2>
251
252       <table cellpadding="0" cellspacing="0">
253       #{matrix}
254       </table>
255
256       <address>&copy; ASRALL 2010 - All rights reserved (watch it pay)</address>
257       </body>
258       </html>
259
260   HTML
261   end
```

10 Tutoriel : Support de Infiniband dans un environnement personnalisé

Support d'Infiniband sur Grid5000

Modules Infinband
Tests de performance
Enregistrement d'un environnement compatible

Licence ASRALL Nancy-Charlemagne
(Sébastien BADIA <seb@sebian.fr> <badia.seb@gmail.com> - Projet tutoré 2009-2010)

24 mars 2010

Table des matières

1 Déploiement

1.1 Upgrade Debian Lenny vers Testing

L'upgrade du système n'est pas obligatoire pour installer les drivers. Cependant certains outils ne sont pas disponibles dans Lenny, ou sont trop anciens...

L'upgrade est une mise à jour classique, pour ce tuto nous utiliserons un environnement *lenny-x64-base*, disponible dans la base des environnements de Grid5000.

Passage en *testing* :

Commencer par remplacer les occurences de **lenny** dans le fichier */etc/apt/sources.list* par **testing**

```
node: apt-get update && apt-get dist-upgrade
node: apt-get install firmware-bnx2 firmware-linux-nonfree firmware-linux firmware-linux-free
```

Note : Vous pouvez répondre par défaut à toutes les questions lors du processus de Màj, l'installation de "firmware-linux-nonfree" règle des soucis de modules avec le passage au noyau 2.6.32

1.2 Erreur de udev avec le noyau

Si lors du `dist-upgrade`, cette erreur survient :

```
Errors were encountered while processing:
/var/cache/apt/archives/udev_150-2_amd64.deb
```

Vous pouvez alors exécuter cette commande :

```
node: dpkg --configure -a
```

Cela permet de configurer touts les paquets restés en attente suite à l'erreur de udev.

Afin de rebooter sur le noyau 2.6.32 et continuer la mise à jour, il enregistrer son environnement (tgz-g5k), puis préciser les nouveaux noyaux et initrd installés (2.6.32-trunk-amd64), dans le *.env*, ou le *.dsc*. Redéployer avec le nouveau *.env*, ou le *.dsc* et relancer la commande de `dist-upgrade` pour terminer les mises à jour (Cette opération de redéploiement est apparenté à un reboot sur un pc classique).

On peux maintenant enregistrer son environnement [1] sur le *frontend*, afin de conserver un système upgradé propre, le *.env* n'a plus besoin d'être modifié.

1.3 Drivers Infiniband

Infiniband est entièrement intégré et utilisable sur les noyaux récent de linux, il vous faut donc juste activer certains modules.

Deux options s'offrent alors à vous, soit vous activer le module avec un *modprobe* après chaque démarrage du système.

Soit vous ajouter ces modules dans le fichier */etc/modules*, ceux-ci seront ainsi chargé au démarrage du système.

- mlx4_ib Module supportant la plus part des cartes Mellanox Infiniband
- rdma_ucm
- ib_umad
- ib_uverbs
- ib_ipoib Module pour le support de ip over infinband
- ib_srp
- bnx2

```
node: modprobe mlx4_ib && modprobe rdma_ucm && modprobe ib_umad
node: modprobe ib_uverbs && modprobe ib_ipoib && modprobe ib_srp && modprobe bnx2
```

1. Réf : https://www.grid5000.fr/mediawiki/index.php/Deploy_environment (section **Create a new environment from a customized environment**)

1.4 Personalisation

Changer le mot de passe root (defaut = grid5000) :

```
node: passwd
```

Créer votre utilisateur [2] (exécuter la commande `id` sur un *frontend* afin de récupérer les informations à fournir ; Le nom du groupe correspond théoriquement à la ville d'inscription) :

```
node: addgroup --gid <GID> <NOM_GROUPE>
node: adduser --uid <UID> --ingroup <NOM_GROUPE> <LOGIN>
```

Enregistrer l'environnement [3].

2 Tests de reconnaissance

```
node: ibv_devinfo
node: ibstat
```

2.1 Ping Over Ib

Communication entre deux machines (Ping Over Ib)
Sur la première machine on va déterminer le guid de la carte pour que la deuxième machine puisse "pinger" :

```
node: ibstat -p
```

Sur la seconde :

```
node: ibping -G <guid-hote-vise>
```

2.2 RDMA

Remote Direct Memory Access sur Infiniband (Bande Passante)
Sur la première machine :

```
node: ib_rdma_bw
```

Sur la seconde :

```
node: ib_rdma_bw <Node1>
```

2.2.1 Perftests et Ibutils

Les Paquets Perftest et Ibutils, apportent un panel de commandes de tests supplémentaires, les classiques test de ping-pong mais aussi bien d'autres.

2. Réf : https://www.grid5000.fr/mediawiki/index.php/Deploy_environment (section **Customization**)
3. Réf : https://www.grid5000.fr/mediawiki/index.php/Deploy_environment (section **Create a new environment from a customized environment**)

11 Tutoriel : Support de Myrinet dans un environnement personnalisé

Drivers Myrinet pour Grid5000

Compilation des drivers
Contruction des paquets Debian
Enregistrement d'un environnement compatible

Licence A.S.R.A.L.L. Nancy-Charlemagne
(Julien VAUBOURG <julien@vaubourg.com> - Projet tutoré 2009-2010)

13 février 2010

Table des matières

1 Upgrader son environnement

1.1 Upgrade

L'upgrade du système n'est pas obligatoire pour installer les drivers. Toutefois, une fois les différentes compilations effectuées, il ne sera plus temps d'upgrader le système, au risque de devoir tout recompiler.

L'upgrade se fait à partir d'un environnement *lenny-x64-base* (au moment de ce tuto), disponible dans la base des environnements.

Passage en *testing* :

```
node: sed -i "s/lenny/testing/" /etc/apt/sources.list
node: apt-get update
node: apt-get -y dist-upgrade => reponse par defaut a toutes les questions.
node: apt-get install 'firmware-bnx2*'
```

Enregistrer son environnement[1] sur le *frontend*, afin de conserver un système upgradé propre.
La suite de ce tuto (construction des paquets) pourra se faire sans redéployer.

1.2 Erreur habituelle

Si lors du `dist-upgrade`, cette erreur survient :

```
Errors were encountered while processing:
/var/cache/apt/archives/udev_150-2_amd64.deb
```

Exécuter cette commande :

```
node: dpkg --configure -a => tout valider.
```

Puis exécuter la commande qui suit le `dist-upgrade` dans la procédure plus haut, puis enregistrer son environnement en précisant les nouveaux noyaux et initrd installés, dans le *.env*. Redéployer et relancer la commande de `dist-upgrade` pour terminer les mises à jour (un simple reboot aurait pu suffire, mais ça ne semble pas possible).

2 Recompilation du noyau et construction d'un paquet

Les drivers Myrinet doivent impérativement être compilés avec le même compilateur que le noyau. Le seul moyen de s'en assurer est de recompiler le noyau (`2.6.32` au moment de ce tuto).

```
node: apt-get install linux-source-<KVERSION>
node: cd /usr/src
node: tar xvjf linux-source-<KVERSION>.tar.bz2
node: cd linux-source-<KVERSION>/
node: cp /boot/config-<KVERSION_ANCIEN> .config
node: make menuconfig => exit puis yes.
node: make-kpkg --revision=<KVERSION> --append-to-version=myrinet kernel-image
node: mv linux-image-<KVERSION>myrinet{_<KVERSION>_,_}amd64.deb => juste plus joli.
node: scp ../linux-image-<KVERSION>myrinet_amd64.deb <LOGIN>@frontend: =>
    sauvegarde.
```

[1] Réf : https://www.grid5000.fr/mediawiki/index.php/Deploy_environment (section **Create a new environment from a customized environment**)

3 Compilation des drivers et construction d'un paquet

Télécharger les drivers[2] (version actuelle : *mx_1.2.11.tar.gz*). Pour obtenir le login et le mot de passe, remplir le formulaire dédié[3].

Attention : le driver *Myri10GE_Linux_1.5.1*[4] permet uniquement de simuler de l'ethernet classique sur une carte Myrinet (la transformant ainsi en une vulgaire carte ethernet 10G, au mieux). C'est donc bien le driver *mx_** qu'il faut récupérer.

3.1 Compiler le driver dans l'optique de faire le paquet

```
1 node: tar xvzf mx_<MXVERSION>.tar.gz
2 node: cd mx-<MXVERSION>
3 node: ./configure --with-linux=/usr/src/linux-source-<KVERSION> --enable-kernel-lib
4 node: make && make install
```

Le driver s'est installé dans */opt/mx*. ces fichiers serviront uniquement à connaître la liste précise des fichiers qui lui sont associés. Recompiler le driver en installant les fichiers à l'emplacement souhaité (dans */usr/local*).

```
1 node: ./configure --with-linux=/usr/src/linux-source-<KVERSION> --enable-kernel-lib
      --prefix /usr/local
2 node: make && make install
```

3.2 Préparation du paquet

3.2.1 Copie des fichiers

```
1 node: DEB_MYRINET=/tmp/mx-<MXVERSION>_<KVERSION>myrinet_amd64
2 node: mkdir -p $DEB_MYRINET/usr/local
3 node: for i in $(find /opt/mx/* | sed "s/^\/opt\/mx\///"); do [ -d "/usr/local/$i"
     ] && mkdir -p $DEB_MYRINET/usr/local/$i || cp /usr/local/$i $DEB_MYRINET/usr/
     local/$i; done
4 node: mkdir $DEB_MYRINET/DEBIAN
```

3.2.2 Fichier de version du paquet

```
1 node: vim $DEB_MYRINET/DEBIAN/control
```

[2] http://www.myri.com/scs/download-mx10g.html
[3] http://www.myri.com/scs/loginrequest.php (si vous n'êtes pas assez convaincant, le support vous demandera un numéro de série : « *Please send a serial number from one component - the 6-digit number prefixed by "SN" on the white label - so that we can verify your license* »)
[4] http://www.myri.com/scs/download-Myri10GE.html

Ajouter :

```
Package: mx-<MXVERSION>-<KVERSION>myrinet
Version: 0.1
Section: base
Priority: optional
Architecture: amd64
Depends: linux-image-<KVERSION>myrinet
Maintainer: Julien VAUBOURG <julien@vaubourg.com>
Description: Drivers compiled with the same compilator than linux-image-<KVERSION>
   myrinet
```

3.2.3 Service de lancement des drivers

```
node: mkdir -p $DEB_MYRINET/etc/init.d
node: vim $DEB_MYRINET/DEBIAN/etc/init.d/myrinet
```

Ajouter :

```
#!/bin/sh

### BEGIN INIT INFO
# Provides:             mx_local_install
# Required-Start:
# Required-Stop:
# Default-Start:        2 3 4 5
# Default-Stop:
# Short-Description:    Launch and stop the myrinet drivers
### END INIT INFO

case "$1" in
        start)
                /usr/local/sbin/mx_local_install
                /etc/init.d/mx start
                /sbin/ifconfig myri0 up
        ;;

        stop)
                /sbin/ifconfig myri0 down
                /etc/init.d/mx stop
        ;;

        restart)
                /etc/init.d/myrinet stop
                /etc/init.d/myrinet start
        ;;

        *)
                echo "Usage: /etc/init.d/myrinet {start|stop|restart}"
                exit 1
esac

exit 0
```

3.2.4 Lancement automatique du service

```
1 node: echo -e \#\!/bin/sh \\n/usr/sbin/update-rc.d\ {myrinet\ defaults,-f\ mx\
    remove} > $DEB_MYRINET/DEBIAN/postinst
2 node: chmod 755 $DEB_MYRINET/DEBIAN/postinst
3 node: chmod +x $DEB_MYRINET/etc/init.d/myrinet
```

3.3 Construction et sauvegarde du paquet

```
1 node: dpkg-deb -b $DEB_MYRINET
2 node: scp ${DEB_MYRINET}.deb <LOGIN>@frontend:
```

4 Enregistrement d'un environnement Myrinet

4.1 Installation des drivers

Depuis un environnement *lenny-x64-base* (au moment de ce tuto) éventuellement upgradé en *testing*[5] :

```
1 node: dpkg -i linux-image-<KVERSION>myrinet_amd64.deb mx-<MXVERSION>_<KVERSION>
    myrinet_amd64.deb
2 node: mkinitramfs -o /boot/initrd.img-<KVERSION>myrinet <KVERSION>myrinet
```

4.2 Customisations utiles

Changer le mot de passe root :

```
1 node: passwd
```

Créer votre utilisateur[6] (exécuter la commande `id` sur un *frontend* afin de récupérer les informations à fournir ; Le nom du groupe correspond théoriquement à la ville d'inscription) :

```
1 node: addgroup --gid <GID> <NOM_GROUPE>
2 node: adduser --uid <UID> --ingroup <NOM_GROUPE> <LOGIN>
```

Ajouter l'utilisateur aux sudoers :

```
1 node: echo "<LOGIN> ALL=(ALL) ALL" >> /etc/sudoers
```

Enregistrer l'environnement[7] et le redéployer (en n'oubliant pas de changer le initrd et le noyau dans le *.env* par ceux taggués *mirynet*).

Les drivers seront automatiquement chargés.

[5] Voir la section **Upgrader son environnement**
[6] Réf : https://www.grid5000.fr/mediawiki/index.php/Deploy_environment (section **Customization**)
[7] Réf : https://www.grid5000.fr/mediawiki/index.php/Deploy_environment (section **Create a new environment from a customized environment**)

5 Tests

5.1 Reconnaissance de la carte

```
1 node: mx_myri_info
```

5.2 Communication entre deux machines

Sur la première machine :

```
1 node: mx_pingpong -s
```

Sur la seconde :

```
1 node: mx_pingpong -M 4 -E 1048577 -d <NODE>.<SITE>.grid5000.fr:0
```

Si `mx_pingpong` répond une douzaine de lignes de stats de performance, c'est que ça fonctionne.

6 Références

- Page Grid5000 dédiée à Myrinet :
  https://www.grid5000.fr/mediawiki/index.php/Myrinet

- Page Grid5000 dédiée au déploiement et à l'enregistrement d'environnements :
  https://www.grid5000.fr/mediawiki/index.php/Deploy_environment