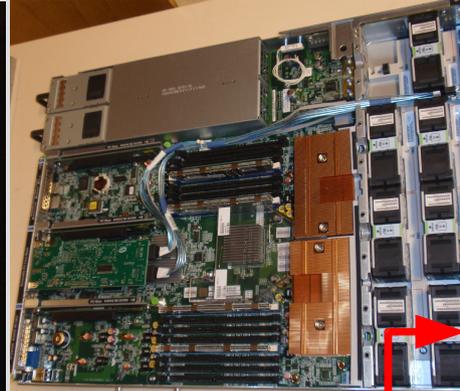
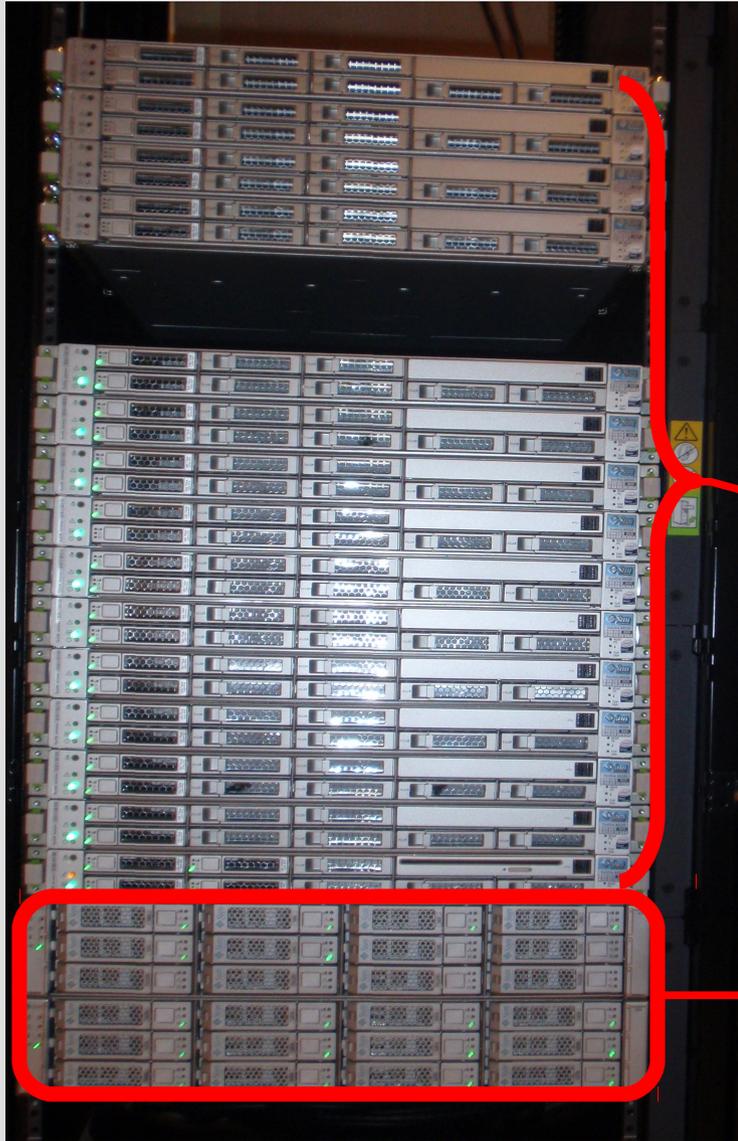


# Cluster URBM-Sys. Dyn.



- FUNDP le 05/01/2010
- Unité de Recherche en Biologie Moléculaire
- Unité de Systèmes Dynamiques (département de math)
- Nicolas Delsate & André Füzfa

# C'est quoi un cluster ?



Des noeuds  
de calculs =  
 $14 \times 8 = 112$   
processeurs

Une baie  
de disques  
7 To



# Mais encore...

Des heures  
d'installation et de  
résolution de bugs et  
problèmes en tout  
genre



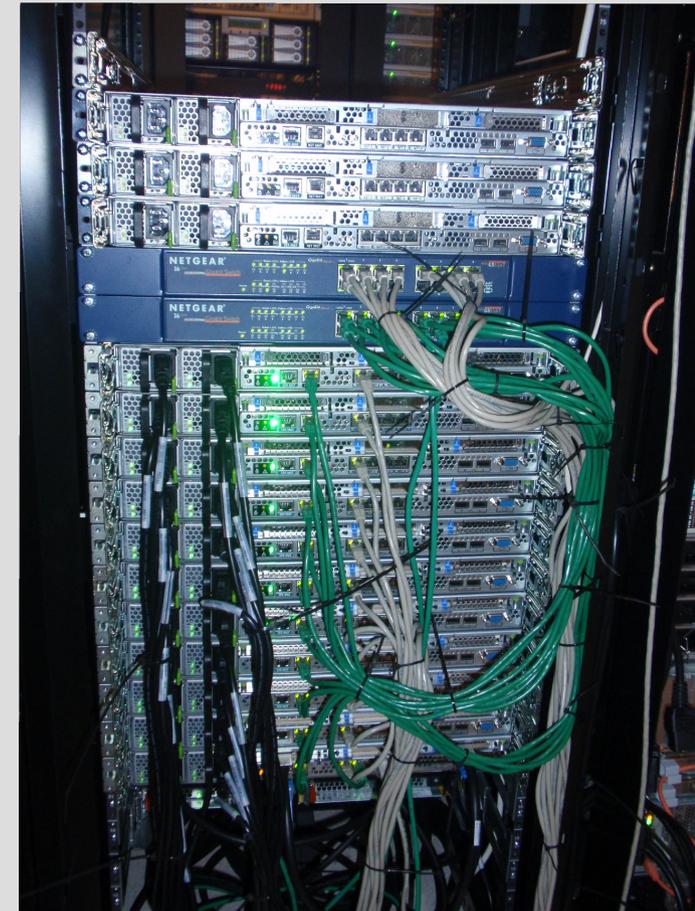
D'autres clusters  
(nous sommes  
dans les armoires  
de l'ISCF).

Des cables et des  
noeuds ...



Des gens pour la  
maintenance et  
l'installation.

Didier Belhomme,  
Frédéric Wautelet,  
Fabrice Berger,  
Eric Bareke, Bertrand De Meulder, André Füzfa et Nicolas  
Delsate



# Quelques chiffres

- 14 noeuds =>  $14 \times 8 = 112$  processeurs
- 16 Go RAM/noeud et 4 To de Disque
- 1 machine frontale (machine de connexion sur laquelle vous soumettez vos jobs, le cluster fait le reste grâce à SGE pour les envoyer sur les autres noeuds...)
- Plus de 40 000€ investis par l'URBM et 13 000€ investis par le département et/ou l'unité de systèmes dynamiques.

# Quels programmes sont disponibles ?

- Pour compiler :
  - Tout compilateur "instalable" par paquet  
gfortran, gcc, ...
  - Ifort (compilateur fortran + debugger +  
openMP, lapack)
- Pour développer :
  - Emacs, gedit, nano, vi, ...
- Ce qu'il n'y a pas, parce que l'on ne permet pas de post-traitement :
  - Matlab, gnuplot



# Sur la frontale :

`ssh -X monLogin@urbm-cluster.urbm.fundp.ac.be`

- Ce que vous pouvez faire
  - Développer et soumettre vos jobs (SGE)
  - Tester : exécuter votre programme (même en parallèle) mais pas plus de 2 minutes,
  - Un peu de pré-post-traitement type cat, tail, head, ...
- Ce que vous NE pouvez pas faire
  - Exécuter des programmes long (>2min)
- Vous ne pouvez JAMAIS vous connecter aux autres noeuds !

# SGE (1/6) : Sun Grid Engine

- SGE est un logiciel de gestion de queues distribuées. Chaque utilisateur peut envoyer des travaux sous forme de script.
- L'avantage principal consiste en la répartition de la charge de calcul sur les machines du cluster.
- Après la lecture de ce document l'utilisateur "saura" soumettre des jobs, suivre les exécutions, et les arrêter éventuellement. Il doit être uniquement considéré comme une première aide.
- Pour toute information complémentaire veuillez consulter les man pages ou la documentation de SGE.

# SGE (2/6) : Sun Grid Engine

- qstat      pour voir l'état des jobs
- qdel      pour supprimer un job
- qsub      pour soumettre un job (ou un job paramétrique ou un job parallèle)

pour avoir de l'aide : **man** qsub par exemple

Mais aussi

- qmon      pour lancer l'interface graphique
- qhost     pour voir l'état des machines



# SGE (3/6) : qstat informations

- qstat donne l'état de SES propres jobs (pas ceux des autres)
- qstat -f donne l'état de tous les noeuds
- qstat -u UserBidon donne l'état des jobs de "UserBidon"

```
qstat -u bdemeulder
```

job-ID	prior	name	user	state	submit/start at	queue	slots ja-task-ID
2839	0.75031	Network_fi	bdemeulder	r	11/26/2009 12:00:20	all.q@n10.bioinfo.urbm	1

- qstat -j 2839  
donne tout plein d'informations sur le job portant le job-ID numéro 2839



# SGE (4/6) : qdel supprimer

- qdel 2839                    supprimer le job ayant la job-ID 2839 (seulement si c'est le vôtre !)
- qdel -f 2839                pour forcer (on ne sait jamais que la première instruction ne fonctionne pas)

- États d'un job

Category	State	SGE Letter Code
Pending	pending	qw
	pending, user hold	qw
	pending, system hold	hqw
	pending, user and system hold	hqw
	pending, user hold, re-queue	hRwq
	pending, system hold, re-queue	hRwq
	pending, user and system hold, re-queue	hRwq
Running	running	r
	transferring	t
	running, re-submit	Rr
	transferring, re-submit	Rt
Suspended	job suspended	s, ts
	queue suspended	S, tS
	queue suspended by alarm	T, tT
	all suspended with re-submit	Rs, Rts, RS, RtS, RT, RtT
Error	all pending states with error	Eqw, Ehqw, EhRqw
Deleted	all running and suspended states with deletion	dr, dt, dRr, dRt, ds, dS, dT, dRs, dRS, dRT



# SGE (5/6) : qmon

interface graphique

- Job control : pour voir les jobs

- Pending job :  
soumis non encore exécuté
- Running job :  
en exécutions
- Finished job :  
terminés

possibilité de suspendre un job (également avec la commande qhold)

- Queue control — pour voir l'état des noeuds

- Le reste ne vous intéresse pas !

- **NE PAS UTILISER** submit job pour soumettre ses jobs



# SGE (6/6) : qsub soumettre un job

- Remarque : une fois un job soumis, vous pouvez vous déconnecter et il continue.
- `qsub script.sh` soumettre votre script
- `qsub -t 1-10 job.sh` soumettre un job 10 fois
- Sans argument
- Avec les options indispensable :
  - `-cwd` : lance le job a partir du répertoire courant. Utile, car les fichiers de sortie iront alors dans ce répertoire.
  - `-j y` : pour concaténer les fichiers de sortie (\*.o \*.e)
  - `-m e` : pour envoyer un email a la fin du job (quand ça fonctionne ...)
  - `-S /bin/bash`: pour définir le shell par défaut



# Soumettre un job séquentiel

Sera le nom que vous verrez avec qmon

- Créer un script de soumission `pgmSoumis.sh`

```
#!/bin/sh → C'est du bash
#$ -S /bin/bash → Dis à SGE que c'est du bash
#$ -cwd → Dis à SGE qu'on travaille tjs dans le
répertoire dans lequel on se trouve
cd /home/math/nomUser/RECHERCHE/
./monEx.x > monOut.dat && ./unAutreExe
exit 0
```

On se met au bon endroit TJS → `cd /home/math/nomUser/RECHERCHE/`

Un exécutable ← `./monEx.x > monOut.dat && ./unAutreExe`

C'est du bash → `#!/bin/sh`

Et éventuellement un autre → `./unAutreExe`

- Soumettre votre script dans une console

```
qsub pgmSoumis.sh
```



# Soumettre un job paramétrique (1/3)

## *Préparer son code*

- En C

```
#include <stdio.h>
#include <iostream>
using namespace std;
int main(int argc, char **argv)
{
    long double a,b,c;
    a=(long double)atof(argv[1]);
    b=(long double)atof(argv[2]);
    c=(long double)atof(argv[3]);
}
```

- En Fortran

```
PROGRAM coucou
    CHARACTER(LEN=60) :: NomFich
    IF(IARGC()==0) THEN
        NomFich='donnee.dat'
    ELSE
        CALL GETARG(1,NomFich)
        si vous voulez un nombre
        read(NomFich,*) NomNbre
    END IF
END PROGRAM coucou
```

équivalent de IARGC()

- COMMAND\_ARGUMENT\_COUNT()
- NARGS()

équivalent de GETARG(1,NF)

- GET\_COMMAND\_ARGUMENT(1,NF)



# Soumettre un job paramétrique (2/3)

## *Faire un script et soumettre*

- Créer un script de soumission `scriptAr1.sh`

```
#!/bin/bash
#$ -S /bin/bash
cd /home/math/nomUser/RECHERCHE/
#$ -cwd
#Dit a SGE que c'est un "array job", avec
#"tasks" allant de 1 a cptL par pas de 1.
#$ -v SGE_TASK_FIRST=1
#$ -v SGE_TASK_LAST=12
#$ -t 1-60
```

#Quand une commande simple dans un "array job" est envoye a un #noeud, son "task number" est stocke dans la variable #SGE\_TASK\_ID. Donc nous pouvons utiliser la valeur pour mettre #les resultats qu'on veut.

```
./monExe $SGE_TASK_ID $SGE_TASK_LAST > a.dat
```

- Soumettre le script en console: `qsub scriptAr1.sh`



# Soumettre un job paramétrique (3/3)

## *Ou faire un autre script et soumettre*

- Créer un script de soumission `scriptArray.sh`

```
#!/bin/bash
#$ -S /bin/bash
#$ -cwd
cd /home/math/nomUser/RECHERCHE/
paramIN=$(cat abc.dat | head -$SGE_TASK_ID | tail -1)
./monExectuable.x $paramIN >> fichierOut.dat
```

- Soumettre votre script dans une console

```
qsub -t 1-7260 scriptArray.sh
```

Pour dire que c'est du "array"

le nombre de fois que votre pgm sera lancé

MAX 75000

# Soumettre un job parallèle

- Paralléliser son code avec MPI ou openMP
- Apprendre à le soumettre via qsub en lui disant que c'est un job parallèle  
Pas encore fait !

# Trucs à savoir dans la console (1/2)

- `size monPgm` : permet de connaître (le premier chiffre que la commande renvoie) la taille minimum, en mémoire, en ko de votre programme. Par exemple 1478438 correspond à 147 Mo.
- `time -p ./monPgm` : permet de connaître le temps d'exécution de votre programme (affiché à la fin de l'exécution).

# Trucs à savoir dans la console (2/2)

- `scp -Crq login@machine:/Repertoire autreLogin@autrePC:/AutreRepertoire/`  
Copie Compressée Réursive (q)silencieuse d'un répertoire d'une machine vers une autre
- `tail -9 monFichier.dat`  
affiche à l'écran les 9 dernières lignes d'un fichier
- `head -3 monFichier.f90`  
affiche à l'écran les 3 premières lignes d'un fichier
- `head -15 | tail -1 monFichier.txt`  
affiche à l'écran la 15ième ligne d'un fichier
- ...

# lfort option de compilation

- -check all : run-time checks on whether array subscript & substring references are within declared bounds + runtime checks for valid pointers +runtime checks for uninitialized variables.
- -g : Produces symbolic debug information in the object file
- -traceback : the compiler generate information in the object file to allow the display of source file traceback information at run time when a severe error occurs
- -debug all : enable debug information and control output of enhanced debug information.
- -ftrapuv : trap uninitialized variables. Initializes stack local variables to an unusual value to aid error detection
- -prec-div : improve precision of floating-point divides (some speed impact)
- -prec-sqrt: determine if certain square root optimizations are enabled
- -O3 : enable -O2 plus more aggressive optimizations that may not improve performance for all programs

# gcc option de compilation

- -Os : optimisation
- -Wall : warning all
- ...

# Attention

- Vous n'êtes pas seul donc on vous demande une bonne "gestion" de vos jobs
- Il n'y a pas de quota mais ce n'est pas une raison pour exagérer !
- Il est toujours possible (pcq petit groupe) de demander pour faire passer son job devant les autres en cas de besoin URGENT.
- Faites l'effort d'optimiser un peu vos codes quand même. Sur des clusters "plus professionnels", l'efficacité des jobs est contrôlée.
- Un peu d'indulgence vis à vis des administrateurs (comme vous l'avez fait jusque maintenant)

# La Doc

- <http://perso.fundp.ac.be/~ndelsate/CLUSTER/>
- <http://wikis.sun.com/display/gridengine62u2/Submitting+Jobs>
- <https://www.wiki.ed.ac.uk/display/EaStCHEMresearchwiki/How+to+write+a+SGE+job+submission+script>
- <http://migale.jouy.inra.fr/faq/calcul/utilisation>
- <http://www.cis.upenn.edu/acg/sge.html>
- SGE dans google
- ...

# A faire dès la première connexion

- À votre première connexion vous changez votre mot de passe :

passwd

puis vous suivez les instructions

## Dans vos papiers

- Numerical simulations were made on the local computing resources at Unité de Systèmes Dynamiques (FUNDP, Belgium).

# Nos problèmes

- Ifort Intel Cluster Toolkit n'est pas installer et pose des problèmes
- Disque quasi plein
- Maintenance en amateur...

# Merci

- Aux gens de l'URBM, Didier Belhomme, Frédéric Wautelet
- Aux "béta-testeur" : André, Benoît et Moi
- Aux gros utilisateurs pour les gros tests : Audrey et moi
- Aux gens que j'ai oublié