

Contrôler ses jobs

La liste des jobs pris en charge par SGE est accessible via la commande `qstat`. Afin de filtrer la sortie pour visualiser uniquement ses propres jobs :

```
qstat -u <user_login>
```

Un job peut être supprimé à l'aide de la commande `qdel` :

```
qdel <job_id>
```

Toutes ces informations peuvent être visualisées à l'aide de l'interface `qmon`.

L'état du cluster et de l'ensemble des nœuds peut être visualisé à l'aide de l'interface `ganglia` accessible à l'adresse : <http://serviclust.toulouse.inra.fr/ganglia/>

Le shell interactif : `qlogin`

Si vous souhaitez lancer des commandes interactives sans passer par l'écriture d'un script, il suffit de lancer la commande `qlogin`. Elle exécute un shell sur un des nœuds du cluster.

Les logiciels / banques disponibles sur le cluster

L'ensemble des logiciels mis à votre disposition est disponible dans le répertoire `/usr/local/bioinfo/bin` avec une description sur le site à l'adresse : <http://bioinfo.genotoul.fr/index.php?id=73>.

Les banques mises à disposition se trouvent sous `/bank`. Un test hebdomadaire est réalisé afin de s'assurer de leur cohérence. Vous pourrez trouver le résultat de ce test sur le site à l'adresse suivante : <http://bioinfo.genotoul.fr/index.php?id=65>.

Afin de rendre l'utilisation du cluster la plus facile possible, l'environnement qui est mis à votre disposition (disques, logiciels, banques) est identique à partir de n'importe quel endroit du cluster.

Quelques logiciels disponibles

Logiciel	Description
Alignement de séquences	
bwa	Alignement via la transformation de Burrows-Wheeler
ncbi-blast	Recherche de similarité dans des banques de données, NCBI Blast
Annotation	
Apollo	Environnement d'annotation expert
ARNnc	
RNA Vienna Package	Dédié à la prédiction / comparaison des ARN
tRNAscan-SE	Prédiction d'ARN de transfert
Assemblage	
newbler	Assembleur de Roche pour le 454
Amos	A Modular, Open-Source whole genome assembler
velvet	Assemblage de novo de « very short reads »
Carte génétique	
Carthagene	Logiciel d'ordonnement de marqueurs.
Phylogénie / Metagénomique	
Mothur	The one-stop source for microbial ecology needs
Phylip	Package de 34 programmes dédiés à la reconstruction phylogénétique
Utilitaires	
R	Logiciel pour des calculs statistiques
EMBOSS	Programmes qui permettent de couvrir l'ensemble des besoins dans l'exploitation des séquences biologiques

Plateforme Bioinformatique Midi-Pyrénées



MEMENTO CLUSTER DE CALCUL

bioinfo.genotoul.fr

support.genopole@toulouse.inra.fr

Avril 2011

L'environnement de calcul

La plateforme Bioinformatique Genotoul met à votre disposition :

- ✓ un cluster de 44 nœuds bi-quad cores, soit un ensemble de 352 cœurs pour exécuter vos jobs (4G de RAM par cœur),
- ✓ bigmem, une machine entièrement dédiée aux calculs coûteux en mémoire possédant 32 cœurs et 256G de RAM,
- ✓ n46 et n47 possédant 24 cœurs et 144G de RAM,
- ✓ hypermem possédant 64 cœurs et 1T de RAM accessible sur demande au support,
- ✓ un espace de stockage « lent » (/save/user), pour vos données, sauvegardé chaque jour et un espace de stockage « rapide » (/work/user) optimisé en écriture pour l'exécution de vos jobs.

Cet environnement de calcul, représenté sur la figure 1, est accessible via le serveur frontal SNP depuis une simple connexion internet.




Figure 1 : schéma de l'environnement de calcul.

Connexion au serveur frontal SNP

- Depuis **Windows** : Putty et Xming
 - Depuis **Linux** et **MacOS** : la commande ssh
- ```
ssh -X <login>@snp.toulouse.inra.fr
```

### Lancer un calcul

Chaque calcul doit être encapsulé dans un script pour pouvoir être exécuté sur le cluster à partir de SNP. Par défaut tout job s'exécute sur 1 cœur avec 4Go de RAM et sur la queue workq.

**Exemple1 : le plus classique**

```
#!/bin/bash
#$ -M <votre-adresse>@mail.fr
#$ -m a
blastall -p blastn -d genbank -i seq.fasta
```

L'utilisateur disposera d'1 cœur de calcul, de 4G de RAM et de 24h de temps de calcul.

**Exemple2 : plus de mémoire et plus de cpu**

```
#!/bin/bash
#$ -M <votre-adresse>@mail.fr
#$ -m a
#$ -q bigmemq
#$ -l h_vmem=50G -l mem=50G -pe parallel_smp 8
blastall -a 8 -p blastn -d genbank -i seq.fasta
```

L'utilisateur disposera de 8 cœurs de calcul, de 50G de RAM et d'un temps de calcul illimité.

**Lancement du script sur le cluster :**  
[user@snp ~]\$ qsub mon\_script.sh

### Lancer un calcul par lot

**Exemple : découper un fichier multifasta et exécuter un blast par fichier découpé.**

**Découper un fichier multi-fasta :**

```
SplitMultifasta.pl --nb_seq_per_file 200 --output_dir all_fasta
```

**Créer le fichier de blast à l'aide des commandes shell**  
Comment connaître son shell ? echo \$SHELL

**Avec le shell tcsh**

```
foreach i (`ls all_fasta/*.fasta`)
foreach? echo "blastall -p blastn -i $i -d refseq_rna -o $i.blast" >> mes_commandes
foreach? End
```

**Avec le shell sh (bash)**

```
$ for i in `ls *.fasta`
> do
> echo "blastall -p blastn -i $i -d refseq_rna -o $i.blast" >> mes_commandes
> done
```

**Lancer les calculs**  
qarray mes\_commandes

## Les paramètres de soumission

| Paramètres                      | Utilisation                                                                                    |
|---------------------------------|------------------------------------------------------------------------------------------------|
| -M                              | Adresse email.                                                                                 |
| -m b e a s                      | Envoie d'un email au début (b), à la fin (e), à l'arrêt (a) du job ou à la suspension (s).     |
| -N                              | Nom du script.                                                                                 |
| -cwd                            | Lancement du script dans le répertoire courant.                                                |
| -o                              | Fichier de sortie du job.                                                                      |
| -e                              | Fichier erreur du job.                                                                         |
| -q workq longq unlimitq bigmemq | Spécifie la queue à utiliser pour l'exécution du job.                                          |
| -l h_vmem XG -l mem YG          | Spécifie la taille mémoire virtuelle (X) et la taille mémoire physique (Y) requise par le job. |
| -pe parallel_X Y                | Spécifie le nombre de cpu requis par le job (Y) dans le mode X souhaité (8 smp fill rr).       |

Pour plus d'options sur la soumission : *man qsub*.

### Les queues disponibles

| Queue    | Caractéristiques                       |
|----------|----------------------------------------|
| workq    | Priorité = 300<br>Temps max = 12h      |
| longq    | Priorité = 200<br>Temps max = 48h      |
| unlimitq | Priorité = 100<br>Temps max = illimité |
| bigmemq  | Priorité = 0<br>Temps max = illimité   |

Pour plus d'information : *qstat -q queue\_name*.