



RÉPUBLIQUE
FRANÇAISE

*Liberté
Égalité
Fraternité*



Géosciences pour une Terre durable

brgm




COMMENT MONOPOLISER LES RESSOURCES DU CLUSTER REGIONAL

Cluster Régional

Ressources de calcul mutualisées à l'échelle de la région
Centre Val de Loire

leto.cascimodot.datacentre-valdeloire.fr

- Ressources de calcul HPC IA visualisation :
 - CPU
 - GPU
 - Stockage
- Environnements logiciels pré-installés mutualisés




Cluster Régional

Ressources de calcul mutualisées à l'échelle de la région Centre Val de Loire

leto.cascimodot.datacentre-valdeloire.fr

- Au 1^{er} décembre 2021 :
 - 23 laboratoires/établissements
 - 146 comptes
 - Plus de 23 000 jobs depuis la mise en service
- nécessité d'utiliser un ordonnanceur pour
- la répartition des ressources entre les différents jobs et utilisateurs
 - le cloisonnement des ressources (CPU/GPU)
 - la supervision des ressources

SLURM



SLURM : principe

Pour bénéficier de ressources vous devez décrire votre job

Un job

- Ensemble de tâches à réaliser nécessitant :
 - Du CPU
 - 1 cœur : job séquentiel
 - plusieurs cœurs : job parallèle
 - Toutes les tâches partagent une zone mémoire sur une même machine : job multithreadé ou à mémoire partagée (cf. OpenMP)
 - Les tâches s'échangent des informations entre elles via une librairie : job parallèle à mémoire distribuée (cf. MPI)
 - De la mémoire
 - Des GPU
 - ...En une durée donnée

Une ressource de calcul

- Un nœud de calcul : une machine physique est composée de plusieurs processeurs contenant eux-mêmes des cœurs physiques

Schématiquement

- *Le cluster est un plateau de Tetris*
- *Les jobs sont des pièces à 3 dimensions (nombre de cœurs, quantité de mémoire, durée)*
- *SLURM est le joueur qui cherche à optimiser le placement sur le plateau dynamiquement*

Pour utiliser au mieux les ressources vous devez connaître votre application

Etat du cluster

- sview
 - Jobs
 - Partitions : regroupement des nœuds ayant les mêmes caractéristiques physiques ou contraintes
 - Nœuds
- gpu_in_use


Partition	Default	Part State	Time Limit	Node Count	Node State	NodeList
cpu	yes	up	infinite	16		node[01-16]
gpu-amd	no	up	infinite	1	mixed	gpu03
gpu-intel	no	up	infinite	2		gpu[01-02]

Name	State	CPU Count	Used CPU Count	Error CPU Count	Sockets	CoresPerSocket	ThreadsPerCore	Real Memory	Tmp Disk
gpu01	mixed	40	20		2	20	1	192040M	0
gpu02	idle	40	0		2	20	1	192040M	0
gpu03	mixed	32	1		2	16	1	257539M	0
node01	allocated	128	128		2	64	1	515392M	895000M
node02	mixed	128	37		2	64	1	515392M	895000M
node03	mixed	128	113		2	64	1	515392M	895000M
node04	mixed	128	85		2	64	1	515392M	895000M
node05	mixed	128	116		2	64	1	515392M	895000M
node06	allocated	128	128		2	64	1	515392M	895000M
node07	mixed	128	126		2	64	1	515392M	895000M
node08	mixed	128	105		2	64	1	515392M	895000M
node09	allocated	128	128		2	64	1	515392M	895000M
node10	allocated	128	128		2	64	1	515392M	895000M
node11	allocated	128	128		2	64	1	515392M	895000M
node12	allocated	128	128		2	64	1	515392M	895000M
node13	mixed	128	57		2	64	1	515392M	895000M
node14	allocated	128	128		2	64	1	515392M	895000M
node15	allocated	128	128		2	64	1	515392M	895000M
node16	mixed	128	122		2	64	1	515392M	895000M

```
fboulahya@leto:~/JourneeCascimodot> gpu_in_use
queue      gpu_in_use      gpu_avail
-----
gpu-intel  1                7
gpu-amd    0                3
```

TRAVAIL EN INTERACTIF

- Pour quel usage
 - Compilation
 - Installation de packages R/python
 - Test
 - Exploration/Visualisation de données
 - Jobs qui nécessitent de l'interactivité (saisie utilisateur)
- Quelle commande :



Si vous ne précisez aucune ressource, un cœur avec 2Gb de RAM pendant 12 heures sur la partition cpu vous sera alloué.

TRAVAIL EN BATCH

- Pour quel usage
 - Compilation
 - Simulation
 - Notebooks
 - ...
- Comment :
 - Description du job dans un fichier
 - Toutes les lignes commençant par #SBATCH seront interprétées par SLURM pour spécifier les ressources du job (cf. mêmes options que srun)
 - On soumet ce fichier à SLURM avec la commande sbatch

TRAVAIL EN BATCH

Exemples

- Indiquer une durée à vos jobs!

```
#!/bin/bash
### Script de soumission SLURM

#SBATCH -J JOB_SEQ
#SBATCH -p cpu
#SBATCH -N 1 -n 1
#SBATCH -t 0:30:00

module load gcc/10.2

./sequentiel.sh
```

```
#!/bin/bash
### Script de soumission SLURM

#SBATCH -J JOB_MULTITHREAD
#SBATCH -p cpu
#SBATCH --ntasks=1 --cpus-per-task=16
#SBATCH -t 0:30:00

#A dec commenter pour jobs OpenMP
#export OMP_NUM_THREADS=$SLURM_CPUS_PER_TASK

python multithread.py $SLURM_CPUS_PER_TASK
```

- Important : si vous avez beaucoup d'écritures privilégiez de travailler sur le disque local des nœuds de calcul

```
#!/bin/bash
### Script de soumission SLURM

#SBATCH -J MON_JOB
#SBATCH -p cpu
#SBATCH --ntasks=64 --nodes=1
#si on veut repartir les process MPI
##SBATCH --nodes=2 --ntasks-per-node=32
#SBATCH -t 0:30:00

SCRATCH=/scratch/$USER/$SLURM_JOB_ID
echo "creation du repertoire $SCRATCH"
srun -m arbitrary -w $SLURM_NODELIST mkdir -p $SCRATCH
echo "copie du home vers local"
srun -m arbitrary -w $SLURM_NODELIST cp -r $SLURM_SUBMIT_DIR/* $SCRATCH
cd $SCRATCH

module load gcc/10.2 openmpi/4.1
#compilation
make

#pas besoin de fichier machinefile ou hostfile
#pas besoin d indiquer le nombre de process mpi (option np) cf. $SLURM_NTASKS
mpirun mpi_write

echo "copie du local vers home"
srun -m arbitrary -w $SLURM_NODELIST cp -r $SCRATCH/out_* $SLURM_SUBMIT_DIR
srun -m arbitrary -w $SLURM_NODELIST rm -rf $SCRATCH
```

```
#!/bin/bash
### Script de soumission SLURM

#SBATCH --nodes 1
#SBATCH --cpus-per-gpu 2
#SBATCH --time 02:00:00
#SBATCH --job-name my_jupyter_notebook
#SBATCH --gres=gpu:1
#SBATCH -p gpu-intel
#SBATCH -t 4:00:00

module load anaconda/2020.11

jupyter notebook --no-browser --port=8081 --ip=$(hostname -s)
```

- N'hésitez pas à nous contacter pour vous faire accompagner

MONITORER VOS JOBS

- `squeue --start -u $USER`
 - Vos jobs, avec une date prévisionnelle pour vos jobs en attente

```
fboulahya@leto:~/JourneeCascimodot> scontrol show jobid -dd 23927
JobId=23927 JobName=JOB_MULTITHREAD
UserId=fboulahya(1003) GroupId=fboulahya(1003) MCS_label=N/A
Priority=8813 Nice=0 Account=brgm QOS=normal
JobState=COMPLETED Reason=None Dependency=(null)
Requeue=1 Restarts=0 BatchFlag=1 Reboot=0 ExitCode=0:0
DerivedExitCode=0:0
RunTime=00:05:01 TimeLimit=00:30:00 TimeMin=N/A
SubmitTime=2021-12-07T12:23:09 EligibleTime=2021-12-07T12:23:09
AccrueTime=2021-12-07T12:23:09
StartTime=2021-12-07T12:23:33 EndTime=2021-12-07T12:28:34 Deadline=N/A
SuspendTime=None SecsPreSuspend=0 LastSchedEval=2021-12-07T12:23:33
Partition=cpu AllocNode:Sid=leto:10285
ReqNodeList=(null) ExcNodeList=(null)
NodeList=node03
BatchHost=node03
NumNodes=1 NumCPUs=16 NumTasks=1 CPUs/Task=16 ReqB:S:C:T=0:0:*:*
TRES=cpu=16,mem=32G,node=1,billing=16
Socks/Node=* NtasksPerN:B:S:C=0:0:*:* CoreSpec=*
JOB_GRES=(null)
  Nodes=node03 CPU_IDs=56-63,120-127 Mem=32768 GRES=
MinCPUsNode=16 MinMemoryCPU=2G MinTmpDiskNode=0
Features=(null) DelayBoot=00:00:00
OverSubscribe=OK Contiguous=0 Licenses=(null) Network=(null)
Command=/home/fboulahya/JourneeCascimodot/multithread.job
WorkDir=/home/fboulahya/JourneeCascimodot
StdErr=/home/fboulahya/JourneeCascimodot/slurm-23927.out
StdIn=/dev/null
StdOut=/home/fboulahya/JourneeCascimodot/slurm-23927.out
Power=
NtasksPerTRES:0
```

```
fboulahya@leto:~> sacct -j 23927 --format=User,JobID,Jobname,partition,state,time,start,end,elapsed,MaxRss,nnodes,ncpus,nodelist
```

User	JobID	JobName	Partition	State	TimeLimit	Start	End	Elapsed	MaxRSS	NNodes	NCPUS	NodeList
fboulahya	23927	JOB_MULTI+	cpu	COMPLETED	00:30:00	2021-12-07T12:23:33	2021-12-07T12:28:34	00:05:01		1	16	node03
		23927.batch	batch	COMPLETED		2021-12-07T12:23:33	2021-12-07T12:28:34	00:05:01	16144K	1	16	node03
		23927.extern	extern	COMPLETED		2021-12-07T12:23:33	2021-12-07T12:28:34	00:05:01	1504K	1	16	node03

MONITORER VOS JOBS



Etat du cluster

- [Ganglia](#)
 - Monitoring des nœuds pendant les calculs pour voir consommation CPU, RAM, réseau, ...

CPU's Total: 2192
 Hosts up: 20
 Hosts down: 0

Current Load Avg (15, 5, 1m):
 60%, 60%, 60%
 Avg Utilization (last hour):
 61%

Overview of leto @ 2021-12-06 11:14



Cascimodot Grid > leto > node05

Host Overview







CSV JSON Inspect Hide/Show Events



CSV JSON Inspect Hide/Show Events



CSV JSON Inspect Hide/Show Events



SUPPRIMER DES JOBS

- scancel jobid
- scancel -u \$USER

A retenir

- Décrire au mieux son job avec a minima une durée réaliste
- Dès que vous avez beaucoup d'écritures privilégiez de travailler sur le disque local des nœuds de calcul
- N'hésitez pas à nous contacter pour qu'on vous accompagne