Utilisation des Moyens de Calculs *[@IMB]* (Slurm)

https://www.math.u-bordeaux.fr/~lfacq/MoyensDeCalcul.pdf

Durée 3h

2 pauses de 5min
H+1h
H+2h

Questions à la volée

Introduction

- Premier réflexe pour faire des calculs :
  utiliser son poste de travail / ordinateur portable
- Mais rapidement bloquant quand les besoins augmentent…

- **Quelles sont les autres solutions disponibles pour les usagers *[de l'IMB]* ?**

Moyens disponibles par complexité/puissance croissante

1. Poste de travail / Portable / « Diskless »

2. Serveurs de laboratoire
ex : IMB - Serveurs Diskless (**`servisu, bureau, compute-1To`**)
fonctionnent à l'identique des diskless - en dépannage ponctuel

3. => PlaFRIM3 – Plateforme Fédérative de Recheche en Informatique et Mathématique
Périmètre : les 3 laboratoires : IMB+INRIA+LaBRI

4. => MCIA – Mésocentre de **C**alcul **I**ntensif **A**quitain – machine **Curta**
Périmètre : toutes les structures universitaires de Nouvelle Aquitaine

5. National (GENCI, Grille Européenne) – sur projet/Dossier

6. Européen… – sur projet/Dossier

Ouvrir un compte

Mot clefs : « imb calcul développement»
https://www.math.u-bordeaux.fr/imb/cellule/rubrique47.html_

- MCIA
  - https://redmine.mcia.fr/projects/cluster-curta/wiki/Comptes_Utilisateurs
  - Se connecter : **`ssh curta.mcia.fr`**
- PlaFRIM3
  - https://www.plafrim.fr/fr/connexion/inscription/
  - Se connecter : **`ssh ssh.plafrim.fr`** (⚠ nécessite un **.ssh/config** particulier)

MCIA & PlaFRIM3 : 2 plateformes au fonctionnement similaire

- Ce sont des **Clusters de calcul**
  - = un grand nombre de machines identiques reliées par un réseau rapide
- Plusieurs centaines d'utilisateurs => file d'attente / « chacun son tour »
- => notion de **job** : on doit décrire ses besoins / ses calculs
  - besoin en ressources (combien de machines/quel(s) type(s), cpu, quantité mémoire, ...)
  - description des calculs (script à lancer)
- => notion de **files d'attente** : on y soumet son job
  - puis on attend qu'il s'exécute quand suffisamment de ressources sont libres
- Même gestionnaire de job « ***slurm »*** sur les deux plateformes MCIA et PlaFRIM3 mais avec un **paramétrage différent**

avertissement !

- l’utilisation des clusters de calculs n’est pas simple...
  (surtout si on ne pratique pas souvent !)
- … et leur mode d’utilisation peut évoluer avec le temps !

- venez demander de l’aide au bureau IMB/MCD 270
  ou votre ingénieur calcul de proximité
- venez faire « contrôler » vos scripts
  - pour partir sur de bonnes bases dès le début en faisant les choix optimaux
  - avant de lancer de grandes campagnes de calcul

⚠ Sobriété ! ⚠

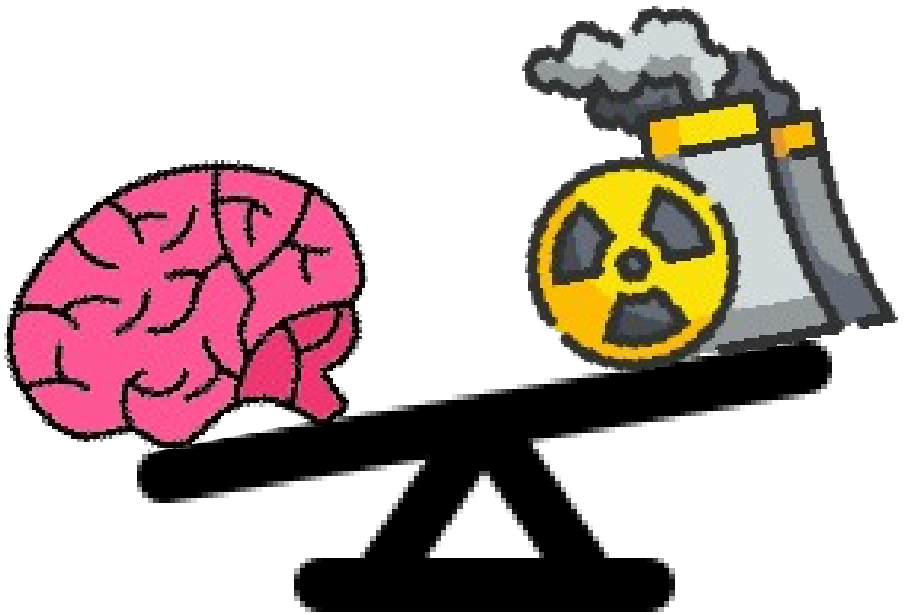

Cogiter vs Calculer ...

Doc & Assistance

- De proximité :
  - Web IMB – les spécificités pour les personnels IMB https://www.math.u-bordeaux.fr/imb/cellule/moyens-de-calcul-et-de-stockage
  - IMB - bureau MCD 270
- Officielle MCIA :
  - Doc : https://redmine.mcia.fr/projects/cluster-curta/wiki
  - Help : https://redmine.mcia.fr/projects/cluster-curta/issues/new
  - Chat/Element : https://enigma.mcia.fr
- Officielle PlaFRIM3 :
  - Doc : https://www.plafrim.fr
  - Help : plafrim-support@inria.fr
  - Chat/Mattemost : https://mattermost.inria.fr/plafrim-users/channels/town-square

Limitations PlaFRIM3

- Par défaut :
  - **Pas d'accès internet en sortie de PlaFRIM3**
    - sauf gitlab académiques, github, sites de référence…
  - => Problèmes pour les « installeurs automatiques »
  - Solutions :
    - Télécharger depuis une autre machine puis recopier sur PlaFRIM3 (**scp**)
    - ou Demande d'ouvertures à envoyer à : plafrim-support@inria.fr
- Transferts entre MCIA et PlaFRIM
  - **scp** à initier obligatoirement depuis MCIA (pour envoyer ou récupérer)

Protection contre les attaques

- Des tentatives répétées de connexions SSH infructueuses entraînent le blocage automatique de l'adresse (IP) de la machine source.
  - Le déblocage se fait automatiquement au bout « d'un certain temps »
  - Particulièrement sensible depuis un Wifi / EduROAM (Adresse IP communes à beaucoup de personnes !)

Terminologie 1/2

- **Machine** = **serveur** = **nœud** [de calcul] = *[compute]* ***node***
- **Frontal / Frontaux** = serveurs d'accès (tous les usagers connectés dessus)
  - Machines «**login**» sur MCIA et «**devel**» sur PlaFRIM3
  - Machines similaires, ok pour petits tests / **Ne pas lancer de gros calculs dessus !**
    (MCIA : limitations des ressources => programmes tués automatiquement)
- **Processeur** / **CPU** / **Cœur** / ***core*** : unité de traitement / exécution
- ***Socket****=connecteur physique pour processeur / Boîtier CPUs → Cache(L3)*
- **Tâche** / ***task*** = processus unix
- ***Thread*** = file d'exécution interne au processus
- ***Job*** = réservation de ressources + lancements de processus dedans
- **GPU** = **G**raphics **P**rocessing **U**nit (Traitement image, IA, Deep Learning, ...)

Terminologie 2/2

- Mode **interactif** – *mode classique hors HPC*
  - Vous lancez votre programme et il s'exécute sous vos yeux
  - Vous voyez les sorties (output)
  - Vous pouvez répondre à des questions (intput)
- Mode **batch** – *spécifique au HPC*
  - Le programme s'exécute sans vous
  - Il peut tourner à tout moment – la nuit par exemple

HPC = **H**igh **P**erformance **C**omputing

vue d'ensemble
MCIA vs PlaFRIM3 ?

MCIA-Curta « régionale »
~11.000 cœurs

- Orienté : **production** = obtention de résultats (peu importe le temps), stabilité
- Un cluster principal - homogénéité
  - ~360 nœuds 96Go / 32 cœurs (**dont 28 nœuds réservés IMB**)(**~20 I2M**)
  - 4 nœuds 3To « bigmem »
  - 4 nœuds 192Go + GPU (2 x p100)
  - 4 nœuds 192Go de visualisation (P4000)
- MCIA ~3 fois plus gros que PlaFRIM

PlaFRIM3 « 3 labos »
~4.000 cœurs

- Orienté : **développement expérimentation**, versions récentes, architectures variées/exotiques, … plus instable
- Plusieurs clusters différents
  - ~40 bora 192Go/36 cœurs (intel)
  - ~20 sirocco (intel) GPU k40m, p100, v100, rtx8000, a100
  - 22 suroit 256Go/48 coeurs (amd)
  - 1 nœud de visu
  - … (KnightsLanding, AMD EPYC, ARM)

Slurm

- Un ***Gestionnaire de jobs***
  - Démarre (et termine!) les *jobs* sur les nœuds
- Un ***Scheduler*** *(ordonnanceur)*
  - ordonnancement des jobs pour exploiter le cluster et satisfaire au mieux tous les utilisateurs
- => Politique de ***scheduling*** (à ce jour)
  - MCIA :
    - *FairShare* + FIFO: ajustement de la priorité pour répartir le temps entre les utilisateurs
  - PlaFRIM3 :
    - *FairShare homéopathique* + *FIFO :* en pratique FIFO = premier arrivé, premier servi !

FIFO = **F**irst **I**n **F**irst **O**ut

3 commandes pour soumettre un job : **`srun,salloc,sbatch`**

`srun` : réserve des ressources et y démarre un job interactif

- **`srun [options] commande arguments`**
  - Ex : **`srun mon_programme ...`**
  - Soumet une demande de réservation-exécution en une seule ligne
  - Mode **Interactif**
  - Les ressources sont libérées à la fin de l'exécution du programme

Usage : tests, exécutions rapides ou interactives, session interactive sur un ou plusieurs nœuds de calcul (compilations/exécutions). *Attente potentielle à chaque lancement*

salloc: réserve des ressources pour une session interactive + **srun**

- **salloc [options]**
  - Soumet une demande de session (shell) avec des ressources réservées
  - Mode **Interactif**
  - On démarre ensuite, dans cette session, des programmes avec **srun** (ou **mpirun**)
  - Les ressources sont libérées quand la session **salloc** se termine (**exit** ou temps écoulé)

Canevas de session :

```
$> salloc [options]
 $> srun [opt1] prog1 arg1
$> srun [opt2] prog2 arg2
$> exit
```

Les commandes s'exécutent sur **la frontale**

Usage : session de travail interactive de plusieurs heures, plusieurs programmes à tester. Un seul temps d'attente pour la session entière.

sbatch: réserve des ressources utilisées en batch + **srun**

- **sbatch [options] script_batch**
  - Soumet une demande de ressource pour une utilisation en mode batch
  - Le script contient des lancements de programmes avec **srun** (ou **mpirun**)
  - Les ressources sont libérées quand le script se termine (fin naturelle ou temps écoulé)

Canevas de script_batch :

```
#!/bin/bash
#SBATCH [options]
#SBATCH [options]
srun [opt1] prog1 arg1
srun [opt2] prog2 arg2
```

⚠ Les commandes s'exécutent sur **le premier nœud du job**

Usage : Campagne de calculs. Possibilité de tester/valider en amont avec **salloc**

Commandes Slurm – recap lancer un job - 3 schémas types

	description	mode	ressources	Options	« run où » ?
srun	***all in one* réservation + exécution**	interactif	*one shot*	CLI	nœuds réservés
salloc + srun	**sessions avec ressources réservées**	interactif	session	CLI	frontale puis srun...
sbatch + srun	**batch avec ressources réservées**	batch	session	CLI+script	1er nœud puis srun...

CLI : Commande Line Interface
= Ligne de Commande

Les principales options de Slurm

Options Slurm ou **`srun`** ?

- Les commandes Slurm de soumission de jobs (**`srun`**,**`sbatch`**,**`salloc`**) ont « vu de loin » les mêmes options
  - La plus part des options sont effectivement génériques
  - Quelques options sont spécifiques (à **`srun`** notamment)

Options de réservation de ressources

- 2 aspects selon les options :
  - 1) Sélection des nœuds de calculs
    - Trouver des nœuds répondants aux critères demandés (mémoire, type processeur, temps, carte GPU, …)
      - Ex : **`--cores-per-socket`** (nb cœurs par chip)
  - 2) Conditions d'exécution
    - Comment utiliser les ressources sélectionnées
      - i.e. Comment répartir les processus à lancer

Options Slurm principales : Nb Nœud/Cœurs/Taches

- **`-n`** : nombre total de **tâches** à lancer (défaut : 1 par nœud) **`(--ntasks)`**
  `sur l'ensemble des nœuds du futur job`
  - **`Sert aussi à l'exécution`**
  - `Autre possibilités :`
    `--tasks-per-node --ntasks-per-core –tasks-per-socket`
- **`-c`** : nombre de **cœurs** par tache (défaut : 1) (**`--cpus-per-tasks`**)
  - Mode multi-thread. Sert à sélectionner les nœuds et à contrôler l'exécution
    `Rq : « -c » * « -n » = nombre de cœurs demandés au total`
- **`-N`** : nombre de **nœuds** demandés (défaut : 1) (**`--nodes`**)
  - Ex : **`-N10`** : 10 nœuds demandés
  - *Range* : **`-N`*`min-max`***
    - **`-N2-6`** : au moins 2 nœuds et jusqu'à 6 si possible. Le job démarre dès 2 nœuds disponibles

Options Slurm - Remarque/syntaxe

- Généralement, ces syntaxes suivantes sont équivalentes :

```
-c10
-c 10
-c=10
--cpus-per-tasks=10
--cpus-per-tasks 10
```

- Sauf... pour **`-I / --immediat`** où seules les syntaxes suivantes - sans espace - fonctionnent : (probablement car l'argument est optionnel)

```
-I
-I60
--immediat=60
```

- Peut-être d'autres exceptions...

Options Slurm courantes : Durées

- **`-t=J-H:M:S`** : durée demandée ou *walltime* (**`--time`**)
  (défaut 1h) *walltime* = temps écoulé (horloge, *clocktime*)
  ~~(à ne pas confondre avec *cputime* = *walltime* * nb coeurs)~~
  ou aussi ***`J-H, J-H:M, H:M:S, M:S, M`***

temps dépassé => job détruit !

Exemples :

- **`… -t 1 … : job d'une minute max`**
- **`… --time 1-2 : 1j et 2h`**
- **`… -t3:4 : 3min 4sec`**
- **`… --time=0:0:30 : 30 sec`** en réalité : arrondi à la minute ?

Options Slurm « courantes » : Choix de la file d'attente (partition)

- **`-p partition`** : demande à ce que le job soit placé dans cette *partition*, ou file d'attente, qui a certaines caractéristiques comme : temps maximum, nombre de nœud maximum, nb max job par utilisateur ...
- une même partition peut contenir différents types de nœud : dans ce cas, **`-C`** permet de choisir les nœuds que l'on veut
- si on ne précise rien, c'est la partition par défaut qui est utilisée

Options Slurm « courantes » : Contraintes sur le choix des nœuds

- **`-C type`** : demande un certain type de nœud - *features constraints* (**`--constraint`**)
- Les *features* disponibles dépendent de la plateforme : type de nœud, architecture, réseau , …

  (plus de détails dans quelques transparents)
- Pour afficher facilement les *features* existantes, alias à mettre dans votre **`$HOME/.bashrc`** :

```
alias sfeatures='sinfo -o "%30N %10c %10m %60f %10G"'
```

Options spécifiques **`srun`** courantes

- **`-I`** : immédiat ou délai max en secondes (**`--immediat`**)
  - Ex : **`srun -I`** … : demande un démarrage immédiate
    `srun I60` … : demande un démarrage d'ici 60 sec maximum sinon abandon

    en pratique : mettre au moins 30 à 60
    (délais de prise en compte par slurm)
- **`--pty`** : pour entrée/sorties interactives
  - utilisation typique : **`srun … --pty bash`**
    démarre un shell interactif
    sur le premier nœud obtenu

Options Slurm plus occasionnelles

- **`--time-min=`*`J-H:M:S`*** : durée minimum demandée (même esprit que **`-N`*`min-max`***)
- **`--job-name=`*`NomDuJob`* `(-J)`** : donne un nom au job
- **`-o`** ***`output_file`*** : fichier pour les sorties classiques (défaut : **`slurm-JOBID.out`**)
- **`-e`** ***`error_file`*** : fichier pour les sorties erreurs (défaut : **`slurm-JOBID.err`**)

Options Slurm plus occasionnelles

- **`--mail-user=mon_email@math.u-bordeaux.fr`**
  adresse e-mail pour recevoir des notifications
- **`--mail-type=BEGIN,END`**
  pour activer les notifications : ici au début et à la fin du job
  autres possibilités :**`FAIL,REQUEUE, TIME_LIMIT, TIME_LIMIT_50, TIME_LIMIT_80, TIME_LIMIT_90`**

`ALL` est équivalent à **`BEGIN,END,FAIL,REQUEUE`**

srun, salloc, sbatch

...premières utilisations concrètes

Job interactif typique avec **`srun`**

une session de travail sur un cœur

- MCIA & PlaFRIM3
  - **`srun -I60 --time=4:0:0 --pty bash`**

    si un coeur est disponible dans les 60 secondes, démarre un shell (bash= interpréteur de commandes) sur un cœur pour une durée max de 4 heures
  - **`srun      --time=4:0:0 --pty bash`**

    idem mais attend indéfiniment qu'un coeur soit libre...
    ...peut-être à 3h du matin! (**ctrl-c** pour arrêter l'attente)

    Quand le srun (bash) se termine, les ressources sont libérées

Job interactif typique avec **`salloc`**

une session de travail sur un cœur

(MCIA & PlaFRIM3)

1) `salloc -I60 –time=4:0:0` : pour réserver les ressources

réserve un coeur pour 4h si disponible dans les 60 secondes

2) `srun --pty bash` : pour aller sur le nœud et y exécuter des commandes...

démarre un interpréteur de commande sur le coeur/noeud réservé

3) `srun mon_job_1` : lancer un programme 1

4) `srun mon_job_2` : lancer un programme 2

5) `exit`

note : **`salloc`** crée un nouvel interpréteur de commandes (*shell*) via lequel les ressources sont réservées et conservées.
Quitter ce *shell* libère ces ressources.

Fichier Batch (non interactif)
calculs en suivant

- **Un batch** = Script bash avec des directives **#SBATCH** (en début de fichier)
  contenant des options Slurm

```
===== fichier mon_batch =====
#! /bin/bash
#SBATCH -n3                    # on demande 3 tâches (c=1 donc 3 cœurs)
#SBATCH --time=2:0:0           # pour 2 heures
srun mon_calcul_1          #lancement de 3 instances de mon_calcul_1
srun mon_calcul_2          #lancement de 3 instances de mon_calcul_2
============================
```

- Utilisation :

```
$> sbatch mon_batch   # soumet le batch dans la file d'attente
```

- Les options en ligne de commande sont **prioritaires** sur les directives **#SBATCH** du script :

```
$> sbatch -n4 mon_batch        # idem sur 4 tâches au lieu de 3
```

Fichier Batch (non interactif)
calculs simultanés

- ```
  ===== fichier mon_batch =====
  #! /bin/bash
  #SBATCH -n4 --time=2:0:0   # on demande 4 cœurs pour 2h...

  srun -n2 mon_calcul_1 & #lancement de 2 instances de mon_calcul_1
  srun -n2 mon_calcul_2 & #lancement de 2 instances de mon_calcul_2

  wait                    # attend la terminaison des 2 calculs
  ============================
  ```

- Utilisation :

  ```
  sbatch mon_batch   # soumet le batch dans la file d'attente
  ```
  ```

Fichier Batch

```
===== fichier mon_batch =====
#! /bin/bash

hostname
#OK
#SBATCH -n3                          # directive ignorée
#SBATCH --time=2:0:0                 # directive ignorée
srun mon_calcul_1           #lancement de 1 instance de mon_calcul_1
srun mon_calcul_2           #lancement de 1 instance de mon_calcul_2
============================
```

- Pas de commande entre **#!**… et **#SBATCH**
  - Commentaires et lignes blanches ok
  - Pour commenter une directive #SBATCH : **##SBATCH**

PlaFRIM3 spécifique : Options Slurm

- **`--exclusive`** : pour demander les nœuds en mode exclusif (personne d'autre que vous)
  - *Permet d'éviter les perturbations dues aux autres utilisateurs qui pourraient arriver sur la même machine (saturation mémoire, perturbation des temps de calcul et des accès disque et réseau)*
  - *Mais, monopolise plus de ressources, => temps d'attente plus long, ...*

  - Ne dispense pas de demander les cœurs/taches dont on a besoin (1 par défaut !)
  - Combiné avec **`-c`** (nb cœurs par tâche) : le **`-n`** (nb tâches) sera choisi automatiquement pour occuper au maximum tous les cœurs de tous les nœuds réservés. Ex : « **-c1** » pour lancer le maximum de tâches (de 1 coeur)

--exclusive (PlaFRIM) + range

- Exemple : comment lancer le maximum de *tâches* de **12** cœurs sur **3** *miriels* ?

miriel

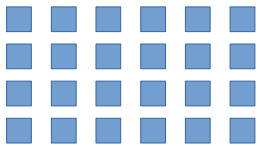

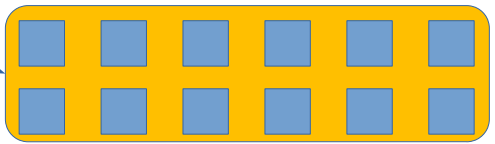

- les *miriels* ont 24 cœurs
- 24 cœurs / 12 par tâche = 2 tâches par nœud
  soit pour 3 nœuds : 3 nœuds * 2 tâches par nœud = 6 *tâches* au total

```
srun --exclusive -C miriel -N3 -c12 mon_prog
```

miriel001 miriel002 miriel003

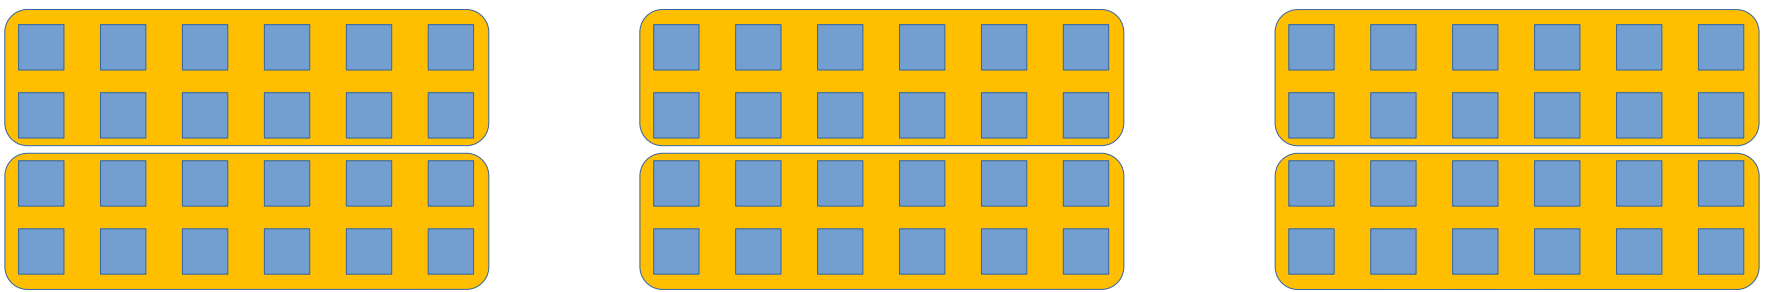

Très pratique pour les « range »

```
srun --exclusive -C miriel -N3-10 -c12 mon_prog
```

PlaFRIM3 spécifique : Options Slurm

- **`-C type`** : demande un certain type de nœud
  features constraints (**`--constraint`**)
  - Type de cluster : **`-C bora`** , **`-C suroit`** , **`-C zonda`** , ...
  - Nœud GPU : **`-C p100`** , **`-C v100`** , **`-C a100`** , ...
  - Architecture CPU : **`-C intel`** , **`-C amd`** , **`-C arm`** , ...
- Pour afficher facilement les *features* existantes, alias à mettre dans votre **`$HOME/.bashrc`** :

```
alias sfeatures='sinfo -o "%30N %10c %10m %60f %10G"'
```

PlaFRIM3 spécifique : *features*

NODELIST	CPUS	MEMORY	AVAIL_FEATURES
sirocco[14-16]	32	385000	sirocco,**intel**,skylake,omnipath,nvidia,tesla,v100
sirocco[07-13]	32	255000	sirocco,**intel**,broadwell,omnipath,nvidia,tesla,p100
zonda[01-21]	64	250000	amd,zen2,zonda
bora[001-044]	36	191000	bora,**intel**,cascadelake,omnipath
brise	96	1030000	brise,**intel**,broadwell,bigmem
enbata[01-02]	64	380000	amd,zen4,enbata,mellanox,amdgpu,mi210
sirocco[18-20]	40	190000	sirocco,**intel**,skylake,nvidia,quadro,rtx8000
sirocco21	48	512000	sirocco,amd,zen2,nvidia,ampere,a100
sirocco[22-25]	64	512000	sirocco,amd,zen3,nvidia,ampere,a100
suroit[01-22]	48	250000	amd,zen4,suroit,mellanox
arm01	224	260000	arm,cavium,thunderx2
diablo[01-04]	64	255000	amd,zen2,diablo
diablo05	128	1030000	amd,zen2,diablo,bigmem
diablo[06-09]	128	1030000	amd,zen3,diablo,bigmem,mellanox
kona[01-04]	256	94000	kona,**intel**,knightslanding,knl,omnipath
sirocco17	40	1030000	sirocco,**intel**,skylake,omnipath,nvidia,tesla,v100,bigmem
souris	96	2990000	souris,sgi,ivybridge,bigmem
suet01	56	250000	suet,**intel**,icelake,intelgpu,gpuflex,flex170
visu01	20	128000	visu
mistral[02-03,06]	20	128000	mistral

MCIA spécifique : Options Slurm

- **`-C type`** : demande un certain type de nœud - *features constraints* (**`--constraint`**)
  - Type de nœud :
    - **`-C compute`** : nœuds par défaut - 32 cœurs, 96Go de RAM (non **imb**)
    - **`-C bigmem`** : idem avec 3To de RAM
    - **`-C visu`** : nœuds avec carte GPU de visualisation (3D)
    - **`-C gpu`** : (ou **`-p gpu`**) nœuds avec carte GPU p100
      nécessite également l'option --**`gres...`**
    - **`-C imb`** : nœuds **compute** mais réservés IMB (ou **`-p imb-resources`**) (idem **i2m**)
- Pour afficher facilement les *features* existantes, alias à mettre dans votre **`$HOME/.bashrc`** :

```
alias sfeatures='sinfo -o "%30N %10c %10m %60f %10G"'
```

MCIA spécifique : *features*

NODELIST	CPUS	MEMORY	AVAIL_FEATURES	GRES
bigmem[01-04]	64	3005500	bigmem	
n[001-035,037-236,243,246,253,	32	92160	compute	
visu[01-04]	32	192699	visu	gpu:2(S:0-
gpu[01-04]	32	192700	gpu	gpu:2(S:0-
n[316-336]	32	92160	i2m	
n[337-364]	32	92160	imb	

MCIA spécifique : Options Slurm pour utiliser les GPU

- **`-C gpu --gres=gpu:1`** : demande un nœud GPU avec une carte GPU
- **`-C gpu --gres=gpu:2`** : demande un nœud GPU avec ses 2 cartes GPU
  - ce qui a pour effet de définir les variables d'environnement suivantes (cas avec 2 GPU demandées) :
    - **`SLURM_STEP_GPUS=0,1`**
    - **`CUDA_VISIBLE_DEVICES=0,1`**
    - **`GPU_DEVICE_ORDINAL=0,1`**

- Warning : Option purement déclarative !
  pour avoir des garanties il faut réserver tous les cœurs de la machine hôte et utiliser toutes les cartes GPU de la machine

Spécifiques MCIA : Options Slurm

- Pas de « **`--exclusive`** » disponible
  (pour éviter le gâchis involontaire)
  - Pour émuler, il faut s'arranger pour « réserver exactement *tous les cœurs* » des machines. Avec des machines ***32 cœurs*** :
  - 1) Sans préciser **`n`** (1 par nœud par défaut) : **`c`** doit être égal à **`32`** :
    `srun -c32 -N5 ...`
  - 2) En précisant **`n`** : (et 32 être un multiple de c !)
    (**`n x c`**) doit être égal à (**`N`** X **`32`**)
    `nbTaches x coeurParTache` == **`NbMachines`** x **`32`**
  - Ex : **`srun -n8 -c16 -N4 ...`**
    8x16 = 4 x 32 = (2x4x16)
    = total de 8 taches de 16 cœurs sur 4 Nœuds
    = soit 2 taches de 16 cœurs sur chaqu'un des 4 nœud

Récap Paramètres → Résultats

paramètres				résultats			
-N Node	-c cores /task	-n nb tasks	options	Nodes	core/ task	task	commentaire
		n		? (1 à n)	1	n	n taches de 1 cœur
	c	n		? (1 à ?)	c	n	n taches de c cœur
N				N	1	N	N taches d'1 cœur sur N nœuds
N	c			N	c	N	N taches de c cœurs
N	c		--exclusive (PlaFRIM)	N	c	max	le max de taches possible sur N nœuds entiers
N		n		N	1	n	n taches d'1 core/N nœuds
N	c	n		N	c	n	n taches de c core/N noeuds

n toujours >= N (sinon N ajusté à la baisse)

Jobs « préemptables »

- Principe :
  - Pour utiliser des ressources libres, il est possible d'aller au-delà des limitation habituelles, mais sans garantie d'exécution
  - Les jobs lancés sur ces partitions peuvent être tués à tout moment si un job plus légitime est lancé et a besoin de ces ressources
  - ~60 secondes avant destruction : Ils reçoivent un signal (SIGTERM) de terminaison (permet de sauvegarder l'état courant)
    - Ils sont alors susceptibles d'être automatiquement relancés une deuxième fois
- MCIA : -p preemptible
- PlaFRIM : -p preempt

Mixage d'options **`salloc/sbatch + srun` ?**

- **`salloc/sbatch`**
  choix des paramètres (-N -c -n ...) initiaux
- **`srun`** hérite par défaut de ces paramètres.
  On peut les redéfinir à conditions de ne pas dépasser les limites des ressources demandées
  (N nœuds / n*c cœurs)
- Utilisation classique : pas de mixage d'options
  - Sinon : testez pour vérifier que cela fait bien ce que vous espérez !

Exemple de session salloc / MCIA

- salloc -N2 -c32 -t10 *#(2x32= 64 cœurs alloués sur 2 nœuds, 2 tâches)*

```
$> srun -c2 hostname | wc -l
32
$> srun -c4 hostname  | wc -l
16
$> srun -N2 -c20 hostname
n358
n357
```

```
$> srun -N2 -c16 hostname
n357
n357
n358
n358
```

Très pratique pour les « range »

```
salloc -N2-8 -c32 -t10
srun         -c16 mon_prog  #lance jusqu'à 16 tâches
```

Exemple de session salloc / MCIA

- salloc -t5 -N2 -n64 → 2x32 cœurs

  $> srun -c16 -n4 hostname → 16x4 cœurs

  n356 / n356 / n355 / n355
  … ok, 4 réponses, 2 fois chaque nom de machine

  $> srun -c16 hostname

  srun: error: (64*16 cœurs demandés !! car n=64)

variables d'environnement SLURM_*** : env | grep SLURM

```
salloc -t10 -N2 -c32
SLURM_NODELIST=n[357-358]
SLURM_JOB_NAME=bash
SLURM_JOB_QOS=normal
SLURM_NNODES=2
SLURM_JOBID=3464698

SLURM_TASKS_PER_NODE=1(x2)
SLURM_CPUS_PER_TASK=32
SLURM_JOB_ID=3464698
SLURM_SUBMIT_DIR=/gpfs/home/lfacq

SLURM_JOB_NODELIST=n[357-358]
SLURM_CLUSTER_NAME=curta
SLURM_JOB_CPUS_PER_NODE=32(x2)
SLURM_SUBMIT_HOST=login02
SLURM_JOB_PARTITION=imb-resources
SLURM_JOB_ACCOUNT=imb
SLURM_JOB_NUM_NODES=2
SLURM_MEM_PER_NODE=9610
```

```
salloc  -t10 -N2 -n64
SLURM_NODELIST=n[357-358]
SLURM_JOB_NAME=bash
SLURM_JOB_QOS=normal
SLURM_NNODES=2
SLURM_JOBID=3464708
SLURM_NTASKS=64
SLURM_TASKS_PER_NODE=32(x2)

SLURM_JOB_ID=3464708
SLURM_SUBMIT_DIR=/gpfs/home/lfacq
SLURM_NPROCS=64
SLURM_JOB_NODELIST=n[357-358]
SLURM_CLUSTER_NAME=curta
SLURM_JOB_CPUS_PER_NODE=32(x2)
SLURM_SUBMIT_HOST=login02
SLURM_JOB_PARTITION=imb-resources
SLURM_JOB_ACCOUNT=imb
SLURM_JOB_NUM_NODES=2
SLURM_MEM_PER_NODE=96100
```

Options Slurm spécifiques MCIA

- Accéder aux 28 machines (standard) réservées pour l'IMB (idem i2m)
  - *prérequis : appartenir au groupe **imb** (vérifier avec la commande « id »)*
  - **`-p imb-resources`** ou **`-C imb`** : cibler uniquement les nœuds IMB
  - **`-p imb,imb-resources`** : pour cibler tous les nœuds
  - pour systématiser, ajouter dans votre **`$HOME/.bashrc`** :
    `export SLURM_PARTITION=imb,imb-resources`
- ~~Particularité des nœuds IMB : **mode boost activé** !~~
  - ~~Fréquence CPU jusqu'à 3,7GHz au lieu de 2,1GHz selon le nombre de cœurs qui travaillent (température / consommation électrique)~~
  - ~~Meilleurs performances mais reproductibilité des temps plus compliquée~~

Réserver de la mémoire

- PlaFRIM3 :
  - Ne sert qu'a sélectionner un nœud avec suffisamment de mémoire
  - Actuellement, pas de contrôle des limites mémoires => **!! les jobs peuvent entrer en conflit pour la mémoire !!**
- MCIA : ~~limite stricte~~ + limite molle
  - **par défaut : 1Go par cœur (automatique)** (3Go=mémoire_totale/nb coeurs=96Go/32)
  - option slurm : **`--mem=90G`** (explicite mémoire max par nœud, unités : K,M,G,T)
    `--mem=0` (implicite : prend automatiquement le max)
    à faire que si on en a réellement besoin !
  - ~~stricte : par banque mémoire autorisées (2x48Go)~~
  - molle : contrôles ponctuels de non dépassement
  - **!! les jobs peuvent entrer en conflit aussi :-) (mais moins fréquemment)**
  - **!! en cas de dépassement, le job est détruit !!**

conclusion : dès que l'on veut travailler de manière déterministe ou précise,
il faut être en mode --exclusif (réel ou simulé) pour avoir des nœuds entiers.
Au MCIA, au delà de 1Go/coeur, il faut systématiquement préciser la mémoire

Commandes Slurm
pour voir l'état des jobs, des nœuds, annuler un job, voir les priorités...

Visualiser l'état des jobs : **squeue**

- **`squeue [-l|--long]`**
  - affiche tous les jobs en file d'attente
  - États du job : *STATE*
    PD=Pending --> **R**=Running --> **GC**=Finalisation
- **`squeue -u $USER [-l|--long]`**
  - Idem mais n'affiche que vos jobs
- PlaFRIM3 : commande « **sudo squeue** ...»

Notations :
[ ] : optionnel
| : choix

Possibilités ici :
squeue
squeue -l
squeue --long

`sudo squeue --long` (PlaFRIM3)

```
JOBID  PARTITION     NAME     USER    STATE     TIME   TIME_LIMIT  NODES NODELIST(REASON)
227780   routage    full1   xxxxxx  RUNNING 2-22:48:16 3-00:00:00      1 bora013
229994   routage 15patien    yyyyy  RUNNING 1-00:40:01 2-23:59:00      1 sirocco07
230027   routage 15patien    yyyyy  RUNNING 2-03:46:36 2-23:59:00      1 sirocco16
230947   routage v12Multi   zzzzzz  RUNNING 2-00:17:04 3-00:00:00      4 bora[001-004]
231219   routage single30   zzzzzz  RUNNING 1-23:19:03 3-00:00:00      4 bora[029-032]
231674   routage sunset_t      ttt  RUNNING 1-20:16:32 2-00:00:00      3 sirocco[08-09,12]
231709   routage     NEDD    uuuuu  RUNNING 1-20:10:02 3-00:00:00      1 sirocco12
231676   routage    S_UNS    uuuuu  RUNNING 1-20:11:02 3-00:00:00      1 miriel048
231677   routage    S_UNS    uuuuu  RUNNING 1-20:11:02 3-00:00:00      1 miriel048
```

Supprimer des jobs : **`scancel`**

- **`scancel JOBID JOBID ...`**
  - Détruit les jobs dont les JOBID sont listés
- **`scancel -u $USER`**
  - Détruit TOUS vos jobs

Visualiser l'état des nœuds et les caractéristiques des files : **`sinfo`**

- **`sinfo [-l]`**
  - affiche les caractéristiques des files d'attentes et l'état des nœuds
  - états (STATE) :
    - **Idle**=Libre
    - **Mixed**=Partiellement utilisé/disponible
    - **Allocated**=Réservé
    - **Down**=arrêté
    - **Drain**=non réservable (administration)

Visualiser l'état des nœuds et les caractéristiques des files : **`sinfo`**

- **`sinfo [-l]`**
  - PARTITION:nom de la partition
  - TIMELIMIT : temps max que l'on peut demander
  - JOB_SIZE : nb max de nœuds que l'on peut demander
  - NODES : nb de nœuds dans cette *partition*
  - STATE : état des nœuds (cf slide précédent)
  - NODELIST : liste des nœuds dans cet état

`sinfo --long` (PlaFRIM3)

```
PARTITION AVAIL  TIMELIMIT  JOB_SIZE ...  GROUPS  NODES  STATE NODELIST
routage*     up 3-00:00:00  1-infinite        all     14   down* bora028,miriel[008,016-017,
                                                                 019-020,022,024,038,043-044,075,081,083]
routage*     up 3-00:00:00  1-infinite        all     12  mixed bora013,miriel[006,018,026,045],
                                                                 sirocco[03,07-10,12,16]
routage*     up 3-00:00:00  1-infinite        all     42  allocated bora[001-004,006,029-036,038-039],
                                                                 miriel[001-004,021,023,048,
                                                                 060,062-064,067-071,073,076,
                                                                 078-079],sirocco[01-02,04-05,11,15,17]
routage*     up 3-00:00:00  1-infinite        all     73   idle arm01,bora[007-012,014-027,037,040],brise,
                                                                 diablo[01-05],kona[01-04],miriel[005,009-015,
                                                                 025,027-037,039-042,050-053,056-058,
                                                                 084-088],sirocco[13-14],souris,visu01
```

Visualiser les priorités des jobs: **`sprio`**

- **`sprio -l`** : priorités
- **`sprio -l -n`** : priorités normalisées
- **`sprio -w`** : poids des différents critères

! sur PlaFRIM3 : vous ne voyez que vos jobs !

Le *backfill* : comment faire démarrer plus rapidement vos jobs !

- le *scheduleur* prévoit d'exécuter les jobs par ordre de priorité
- mais cela créé des trous dans l'ordonnancement
- Il est possible des passer dans ces trous !

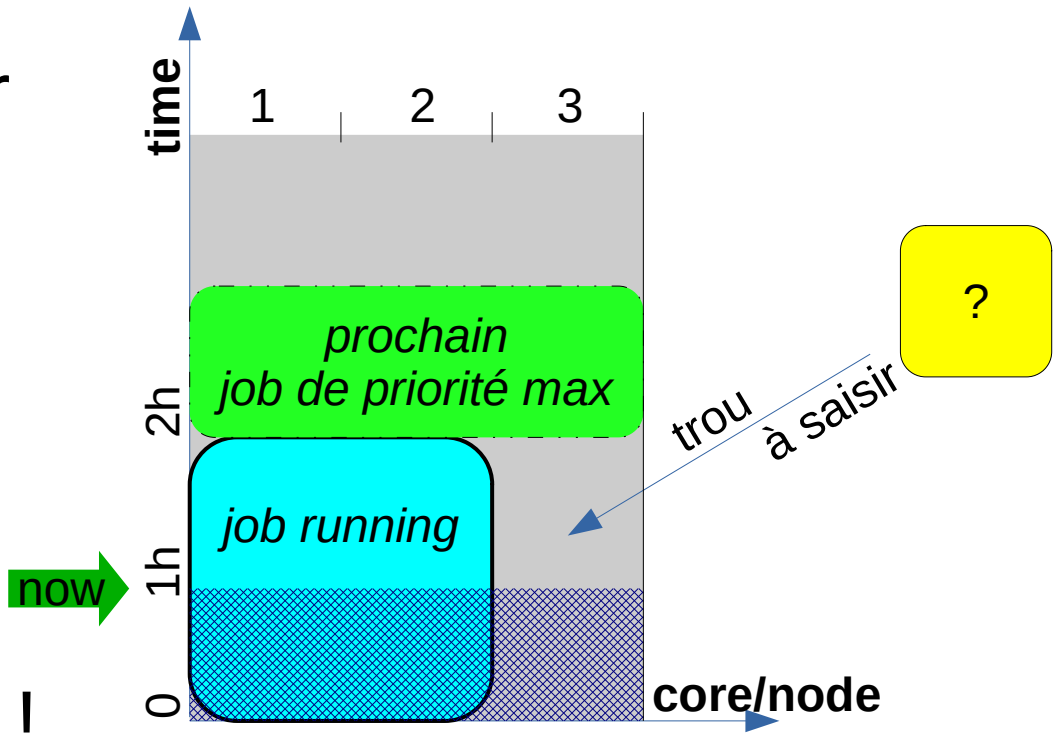

Le *backfill* : comment faire démarrer plus rapidement vos jobs !

- ajuster au mieux son ***walltime*** et minimiser ses ressources pour profiter des «trous» dans le scheduling par priorités
- trop long ou
  trop de cœurs/nœuds
  ou trop de mémoire...
  demandés
  => U wait...

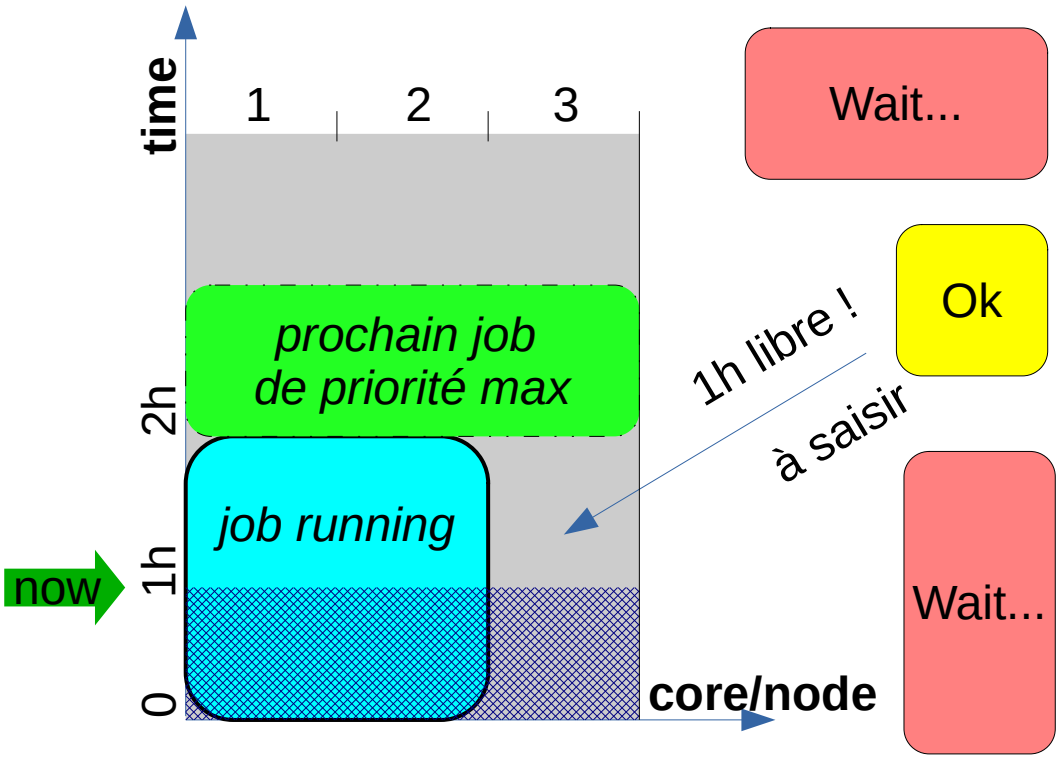

Les modules

Les modules

- **applications** & **bibliothèques** existent en plusieurs versions
  - *En décembre 2021 : ~700 sur Curta et ~200 sur PlaFRIM*
- pour choisir une version et y avoir accès, il faut charger les modules correspondants avec la commande

  `module load nom/du/module`
- les modules sont rangés dans des rubriques qui dépendent de la plateforme
  - Ex : MCIA : **`module load gcc/9.2.0`**
    PlaFRIM3 : **`module load compiler/gcc/9.2.0`**
- les utilisateurs peuvent contribuer en installant des modules partagés
  - Il faut demander à faire partir du groupe ad-hoc
    (MCIA : **`swadmins`** / PlaFRIM3 : **`plafrim-dev`**)
- il peut y avoir des dépendances entre modules = obligation de charger un module avant un autre. Dans certains cas, cela peut se faire automatiquement.
- À noter : Installation automatiques / **guix** (PlaFRIM3), **spack** (curta) …

Les modules - commandes

- Charger un module
  `module load` *`nom/du/module`*
  … Décharger un module
  `module rm nom/du/module`
- Lister les modules existants sur la plateforme :
  `module available` (`abrev` **`: module av`**)
- Cherche un module contenant un motif :
  `module avail |& grep -i` ***`motif`***
  ex : module av |& grep -i matlab

- Lister les modules chargés dans votre session courante :
  `module list`
- Supprimer tous les modules de votre session courante :
  `module purge`

Les modules – notions + avancées

- Charger un module
  `module load` *`nom/du/module[/version]`*
  - *Par défaut, prend la version « la plus récente »*
  - Ex : MCIA : **`module load gcc`**
    PlaFRIM3 : **`module load compiler/gcc`**
- Un module défini ou modifie des variables d'environnement
  - **PATH** : chemin de recherche des commandes
  - **LD_LIBRARY_PATH** : chemin de rech. des librairies dynamiques
  - **INCLUDE_PATH** : chemin de recherche des *includes*
  - *...*

Les espaces disques

backup pérenne	rapide	partagé s/nodes	effacé auto	MCIA Curta	PlaFRIM3
X		X		**`/gpfs/home/$USER`** **`128Go+`**	**`/home/$USER`** **`20Go`**
	X	X	**X**	**`/scratch/$USER`** **`??To`**	
	X	X			**`/beegfs/$USER`** **`1To`**
X		X			**/projets/«TEAM»** **200Go**
	XX		**X**	**/tmp** **??Go**	**/tmp** **??Go**

*iRODS (via MCIA) : **10To** - 3 répliques - en mode « ftp »*
IMB /scratch : ??Go - non sauvegardé

Comment accéder à distance aux fichiers de son compte : sshfs

Permet d'accéder aux fichiers comme s'ils étaient sur votre poste de travail (montage de « système de fichiers »)

- Curta

```
mkdir /tmp/curta
sshfs curta: /tmp/curta
```

  - le répertoire /tmp/curta contient maintenant les fichiers
  - fonctionne en lecture écriture

```
mkdir /tmp/curta-scratch
sshfs curta:/scratch/votrelogin /tmp/curta-scratch
```

- PlaFRIM3

```
mkdir /tmp/plafrim
sshfs plafrim: /tmp/plafrim
```

```
mkdir /tmp/plafrim-beegfs
sshfs plafrim:/beegfs/votrelogin /tmp/plafrim
```

TPs !

(sur le MCIA)

préliminaires

Si vous avez communiqué votre login MCIA :

- Pour utiliser les machines réservées pour la formation, ajoutez l'option « --reservation=formation_slurm »

Sinon, utilisez la partition « -p preemptible »

TP-1 : tester **`srun,salloc,sbatch`**

1) Lancer, le plus simplement possible, un job sur 3 nœuds pour afficher les noms de ces trois nœuds (commande **`hostname`**) en demandant le moins de ressources possible
2) Démarrer une session **`salloc`** de 5 minutes pour pouvoir faire la même chose qu'en 1) en tapant juste « **`srun hostname`** »
3) Utiliser **`sbatch`** pour pouvoir faire la même chose qu'en 1) en faisant juste « **`sbatch mon_batch`** »

Pour éditer des fichiers : ***nano****,* ***emacs****,* ***vi****,* ***vim***
… ou ***scp*** *ou* ***sshfs*** *depuis votre poste !*

TP-1 solutions

1) srun -t0:0:1 -N3 hostname

→ 1 seconde* - 3 nœuds - 3 cœurs

2) salloc -t5 -N3

→ 5 minutes - 3 nœuds - 3 cœurs

srun hostname

exit

3) Fichier mon_batch :

```
#! /bin/bash
#SBATCH -t0:0:1 -N3
srun hostname
```

$> sbatch mon_batch

$> ls -alrt

$> cat slurm-XXXXX.out

* : en réalité, slurm arrondi à la minute supérieure

TP-Préparer une commande « ./cpu »
pour simuler un programme qui tourne sur 1 cœur

Alternative : **`cp ~lfacq/cpu .`**

```
$> cd ; cat > cpu
#! /bin/bash
/usr/bin/time --verbose timeout $* yes > /dev/null
(ctrl-d)                    # ctrl-d : termine le remplissage du fichier

chmod a+rx ./cpu            # on donne le sdroits d'execution

$> ./cpu 5                  # consomme 100 % de CPU sur 1 cœur
                            # pendant 5 secondes et affiche
                            # des statistiques sur l'exécution
```

TP-2

- Lancer en batch, sur 2 nœuds, un total de 2 instances de « ./cpu 30 » pendant 40 secondes
- Pendant ce temps, utiliser à répétition **`squeue`** pour suivre l'état de votre job
- Observer le fichier résultats

```
cp ~lfacq/cpu .
```

TP-2 solution

```
$> cat > batch_30
#! /bin/bash
#SBATCH -N2 -t0:0:40
srun ./cpu 30
(ctrl-d)
```

```
$> sbatch batch_30
```

```
$> squeue -u $USER
```

```
$> ls -alrt
```

```
$> cat slurm-XXXXX.out      # remplace XXXX par le n° du job affiché par « ls »
```

TP-2bis

- Reprendre le TP-2 avec un job d’une durée de 60 secondes avec la commande « ./cpu 180»
- Observer le fichier résultat. Que constatez-vous ?

TP-2bis solution

$> cat > batch_180
#! /bin/bash
#SBATCH -N2 -t0:0:60
srun ./cpu 180
(ctrl-d)

$> sbatch batch_180

$> squeue -u $USER

$> ls -alrt

>$ cat slurm-3538756.out
slurmstepd: error: *** JOB 3538756 ON n355 **CANCELLED** AT 2020-10-26T16:14:43 **DUE TO TIME LIMIT** ***
srun: Job step aborted: **Waiting up to 62 seconds for job step to finish**.
slurmstepd: error: *** STEP 3538756.0 ON n355 **CANCELLED** AT 2020-10-26T16:14:43 **DUE TO TIME LIMIT** ***

Le job a été tué car il a dépassé le temps imparti

Quelques bonnes pratiques :

Contrôler l’utilisation CPU
Contrôler les cœurs affectés

Bonnes pratiques : Vérifier l'utilisation CPU

- Comment vérifier que les cœurs sont bien utilisés comme on pense qu'ils devraient l'être ?
- A faire :
  - avant de lancer une grosse campagne de calcul
  - à chaque modification dans vos scripts de lancement (batch)
  - à chaque changement important sur la plateforme
- 2 Possibilités :
  - En live : **`top`**
  - En batch (permet les vérification à posteriori) : **`time, perf`**

Vérifier l'utilisation CPU avec **`top`**

- Se connecter sur un nœud du job
- Lancer la commande **`top`**
- On regarde les coeurs
  - Touche « 1 » pour afficher (ou cacher) les cœurs
    - Vérifier qu'ils sont « tous » à ~100 %
- On regarde les processus (partie basse de l'affichage)
  - Ok si :
    - Plusieurs processus identiques à 100 % de CPU (processus mono thread)
      - Ex : 23 processus à 100 % <=> 23 cœurs actifs
    - Un processus unique avec une charge > 100 % (processus multithread)
      - Ex : charge CPU à 2300 % <=> 23 cœurs actifs

« top »
(touche « 1 »)

```
top - 16:19:51 up 6 days, 18:25,  2 users,  load average: 2,91, 2,78, 1,34
Tasks: 163 total,   2 running, 161 sleeping,   0 stopped,   0 zombie
%Cpu0  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu1  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu2  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu3  :100,0 us,  0,0 sy,  0,0 ni,  0,0  id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu4  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu5  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu6  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu7  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
MiB Mem : 128768,2 total, 122819,5 free,   2713,0 used,   3235,7 buff/cache
MiB Swap: 262144,0 total, 262144,0 free,      0,0 used. 124479,1 avail Mem
```

CPU

PID	USER	PR	NI	VIRT	RES	SHR	S	%CPU	%MEM	TIME+	COMMAND
9334	lfacq	20	0	2246044	2,1g	15112	R	**100,0**	1,7	0:12.13	TKPok
1	root	20	0	106356	10860	8088	S	0,0	0,0	0:29.51	systemd
2	root	20	0	0	0	0	S	0,0	0,0	0:00.20	kthreadd
3	root	0	-20	0	0	0	I	0,0	0,0	0:00.00	rcu_gp
4	root	0	-20	0	0	0	I	0,0	0,0	0:00.00	rcu_par_gp
6	root	0	-20	0	0	0	I	0,0	0,0	0:00.00	kworker/0:0H-kblockd
7	root	20	0	0	0	0	I	0,0	0,0	0:02.32	kworker/u16:0-rpciod

Processus

« top » phase de calcul séquentielle

```
top - 16:19:51 up 6 days, 18:25,  2 users,  load average: 2,91, 2,78, 1,34
Tasks: 163 total,   2 running, 161 sleeping,   0 stopped,   0 zombie
%Cpu0  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu1  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu2  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu3  :100,0 us,  0,0 sy,  0,0 ni,  0,0   id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu4  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu5  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu6  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu7  :   0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
MiB Mem : 128768,2 total, 122819,5 free,   2713,0 used,   3235,7 buff/cache
MiB Swap: 262144,0 total, 262144,0 free,      0,0 used. 124479,1 avail Mem

  PID USER   PR  NI    VIRT    RES    SHR S  %CPU %MEM  TIME+ COMMAND
 9334 lfacq  20   0 2246044   2,1g  15112 R 100,0  1,7   0:12.13 TKPok
    1 root   20   0  106356  10860   8088 S   0,0  0,0   0:29.51 systemd
    2 root   20   0       0      0      0 S   0,0  0,0   0:00.20 kthreadd
    3 root    0 -20       0      0      0 I   0,0  0,0   0:00.00 rcu_gp
    4 root    0 -20       0      0      0 I   0,0  0,0   0:00.00 rcu_par_gp
    6 root    0 -20       0      0      0 I   0,0  0,0   0:00.00 kworker/0:0H-kblockd
    7 root   20   0       0      0      0 I   0,0  0,0   0:02.32 kworker/u16:0-rpciod
```

« top » phase de calcul parallèle sur 6 cœurs

```
top - 16:20:17 up 6 days, 18:25,  2 users,  load average: 3,03, 2,80, 1,38
Tasks: 163 total,   2 running, 161 sleeping,   0 stopped,   0 zombie
%Cpu0  :  0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu1  : 98,4 us,  0,0 sy,  0,0 ni,  1,6 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu2  : 96,9 us,  0,0 sy,  0,0 ni,  3,1 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu3  :100,0 us, 0,0 sy,  0,0 ni,  0,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu4  : 98,4 us,  0,0 sy,  0,0 ni,  1,6 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu5  : 96,8 us,  0,0 sy,  0,0 ni,  3,2 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu6  : 96,8 us,  0,0 sy,  0,0 ni,  3,2 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
%Cpu7  :  0,0 us,  0,0 sy,  0,0 ni,100,0 id,  0,0 wa,  0,0 hi,  0,0 si,  0,0 st
MiB Mem : 128768,2 total, 122081,6 free,   3450,9 used,   3235,7 buff/cache
MiB Swap: 262144,0 total, 262144,0 free,      0,0 used. 123741,2 avail Mem

  PID USER  PR  NI    VIRT    RES    SHR S  %CPU  %MEM     TIME+ COMMAND
 9334 lfacq 20   0 3367776   2,8g  15112 R 585,7   2,3   1:24.15 TKPok
    1 root  20   0  106356  10860   8088 S   0,0   0,0   0:29.51 systemd
    2 root  20   0       0      0      0 S   0,0   0,0   0:00.20 kthreadd
    3 root   0 -20       0      0      0 I   0,0   0,0   0:00.00 rcu_gp
    4 root   0 -20       0      0      0 I   0,0   0,0   0:00.00 rcu_par_gp
    6 root   0 -20       0      0      0 I   0,0   0,0   0:00.00 kworker/0:0H-kblockd
    7 root  20   0       0      0      0 I   0,0   0,0   0:02.32 kworker/u16:0-rpciod
```

Se connecter sur un nœud attribué à un de mes jobs

- Solution 1 - PlaFRIM3 & MCIA :
  `srun --overlap --jobid ID --pty bash`
  - on arrive par défaut sur le premier nœud du job, préciser si besoin **`-w NODE`**
  - **--overlap** : option pour forcer l'accès, au risque de perturber un peu le job)

Solution 2 - PlaFRIM3 Only : **`ssh NODE`**

Dans les 2 cas : possible uniquement pendant l'exécution d'un job

TP-3 observer un job qui tourne

- Créer un batch pour lancer, sur 2 nœuds, 4 instances de « ./cpu 600 » pendant 5 minutes
- Lancer le batch puis connectez vous sur le premier nœud du jobs pour lancer « `top` » et contrôler la consommation cpu
- Que constatez-vous ?

TP-3 solution 1/2

```
$> cat > batch_600
#! /bin/bash
#SBATCH -N2 -n4 -t5
srun ./cpu 600
(ctrl-d)

$> sbatch batch_600
$> squeue -u $USER
$> srun --overlap --jobid XXXXXX --pty bash
$nodeXX> top                    # touche « 1 » pour afficher les cœurs
```

TP-3 solution 2/2

On constate que la répartition est 3 / 1 au lieu de 2 / 2 à laquelle on s'attend…
La stratégie utilisée est : « une tache sur chaque nœud, puis on remplit les nœuds »

Pour constater la répartition « 3 / 1 au lieu de 2 / 2 » il suffit de faire :

```
$> srun -t1 -N2 -n4 hostname
n294
n293
n293
n293
```

1

3

Vérifier l'utilisation CPU avec **`time`** 1/2

- Remplacer dans votre batch les lignes du type :
  `srun … MonPogramme`
- Par :
  `srun … /bin/time --verbose MonProgramme`
- La commande **`time`** récupère plusieurs compteurs liés à l'exécution dont la ***charge CPU moyenne**** consommée (et une approximation de la consommation mémoire : *Maximum resident…*)
- Comme avec **`top`** un processus avec une charge > 100 % signifie plusieurs coeurs utilisés
  - Ex : charge CPU à 2300 % => 23 cœurs actifs (équivaut à)

** : ou puissance CPU moyenne*

/bin/time exemple d’output

$ /bin/time --verbose ls
...
Command being timed: "ls"
User time (seconds): 0.00
System time (seconds): 0.00
Percent of CPU this job got: 30%
Elapsed (wall clock) time (h:mm:ss or m:ss): 0:00.01
Average shared text size (kbytes): 0
Average unshared data size (kbytes): 0
Average stack size (kbytes): 0
Average total size (kbytes): 0
Maximum resident set size (kbytes): 1024
Average resident set size (kbytes): 0

Major (requiring I/O) page faults: 0
Minor (reclaiming a frame) page faults: 323
Voluntary context switches: 24
Involuntary context switches: 26
Swaps: 0
File system inputs: 0
File system outputs: 0
Socket messages sent: 0
Socket messages received: 0
Signals delivered: 0
Page size (bytes): 4096
Exit status: 0

Vérifier l'utilisation CPU avec **`time`** 2/2

- Avec un code de calcul « CPU intensif » (CPU bound) vous devriez atteindre :
  - 100 % CPU pour chaque code séquentiel (un processus par cœur)
  - c x 100% CPU pour un code avec 'c' thread par processus
- Dans le cas contraire, vos paramètres d'exécution sont probablement incorrectes
- Vérifiez avec **`top`** pendant l'exécution

Vérifier les cœurs réservés

```
srun -c12 grep Cpu /proc/self/status
  Cpus_allowed:000000....00000,00fc003f
  Cpus_allowed_list: 0-5,18-23
```

- Cpu_allowed : masque binaire
- Cpu_allowed_list : liste des cœurs réservés
- Dans vos scripts : **`grep Cpu /proc/self/status`**

Note : la réservation précise des cœurs peut parfois être défaillante

Autres infos diverses

« worker-real » : solution pour traiter un grand nombre de petits jobs

- Cible
  - Lancer un grand nombre de tâches tournant chacune sur moins d'un nœud
  - Gestion de l'état de chaque tâche (traité ou non) / reprise sur problème
- Prérequis
  - Dans un répertoire, écrire un script par tâche
- Fonctionnement
  - Des agents puisent dans ce répertoire les tâches à exécuter
- Avantages
  - Simple, Robuste, Efficace
- https://plmlab.math.cnrs.fr/laurent.facq/worker-real

déport graphique (X11)
ex : matlab, visit, paraview...

- Visualisation 3D, traitement d'image, graphiques interactifs, ...
- Simple...
  - **srun --x11 …** mais très peu performant (voir inutilisable)
- Avec TurboVNC
  - Optimisé/Accéléré
    - Procédure PlaFRIM3 : https://www.math.u-bordeaux.fr/imb/cellule/plafrim3-visualisation-deportee-ex-matlab
    - Procédure MCIA https://redmine.mcia.fr/projects/cluster-curta/wiki/Visualisation_d%C3%A9port%C3%A9e
  - Sur machines dédiées pour la visualisation 3D avec cartes GPU d'accélération
    - PlaFRIM3 : visu01
    - Curta : visu01 à visu04

Fin

Merci pour votre attention !

et surtout merci pour votre feedback à venir :

- Des éléments essentiels manquants ?
- Des éléments pas clairs ou mal dits ?
- Des éléments trompeurs qui vous ont **induit en erreur** ?

=> merci de m'en faire part afin d'améliorer cette présentation :-)