


# Introducción al uso de la infraestructura del NLHPC



# Infraestructura NLHPC




- 266 TFlops
- 5236 cores
- 191 nodos
- +200 TB almacenamiento DDN Lustre
- Infiniband FDR 56Gbps

# Nodos de cómputo Leftrarú

1 tipos de nodo de cómputo:

Slim



## Nodo Slim (cn)

- 132 nodos
- 2 CPUS Xeon E5-2660 v2, 10 cores c.u.
- 48/64 GB RAM DIMM DDR3

# Nodos de cómputo Guacolda

3 tipos de nodo de cómputo:

General



Largemem



## Nodo General (sn)

- 48 nodos
- 2 CPUS Xeon Gold 6152, 22 cores c.u.
- 192 GB RAM DIMM DDR4

## Nodo Largemem (fn)

- 9 nodos
- 2 CPUS Xeon Gold 6152, 22 cores c.u.
- 772 GB RAM DIMM DDR4

# Nodos de cómputo Guacolda


GPU



## Nodo GPU (gn)

- 2 nodos
- 2 CPUS Xeon Gold 6152, 22 cores c.u.
- 2 NVIDIA Volta V100 cada nodo
  - 16GB
  - 5120 CUDA cores cada una
- **192 GB RAM DIMM DDR4**

# Uso de Guacolda-Leftraru







# Gestor de recursos SLURM

- Administra recursos computacionales como CPU y RAM.
- Gestiona las colas de ejecución en clusters.
- Reserva recursos compartidos.





# Particiones Leftraru

- **slims**: partición por defecto, 128 nodos slims, 4 fats (2640 cores).
- **debug**: 4 nodos logins (80 cores).
- **general**: 48 nodos (2112 cores).
- **largemem**: 9 nodos (396 cores). Para tareas con más de 192 GB.
- **gpus**: 2 nodos con 4 tarjetas Nvidia Tesla V100 (88 cores y 20480 GPU cores)
- Uso de nodos logins/debug:
  - Restringido para ejecución (30 minutos)
  - Válido para pruebas, compilaciones y movimiento de datos
- Resto de particiones 30 días de ejecución
  - Uso de *checkpoints*.



# Particiones Leftrarú

- **sinfo**: ver estado de las particiones

```
[root@master2 ~]# sinfo
PARTITION AVAIL  TIMELIMIT  NODES  STATE NODELIST
slims*      up    infinite    2  resv cn[012,027]
slims*      up    infinite    5  mix  cn[005,038,053,105,116]
slims*      up    infinite  123 alloc cn[001-004,006-011,013-026,028-037,039-049,051-052,054-068,070-104,106-115,117-128],cnf[001-004]
slims*      up    infinite    2  idle cn[050,069]
levque      up  3-00:00:00    1  drain levque041
levque      up  3-00:00:00   40  idle levque[001-040]
mics        up    infinite    3  down* cnf001-mic[0-2]
mics        up    infinite    9  idle cnf002-mic[0-2],cnf003-mic[0-2],cnf004-mic[0-2]
debug       up    10:00       4  idle leftrarú[1-4]
largemem    up    infinite    1  resv syntagma001
```



# Enviar trabajos en SLURM



```
[usuario@leftraru1 ~]$ srun hostname
```

1 proceso

cn028

```
[usuario@leftraru1 ~]$ sbatch <job_script>
```

salida comando

```
Submitted batch job 9142401
```

```
[usuario@leftraru1 ~]$ squeue
```

| JOBID   | PARTITION | NAME     | USER | ST | TIME | NODES | NODELIST(REASON) |
|---------|-----------|----------|------|----|------|-------|------------------|
| 9142401 | slims     | pi_levqu | root | R  | 0:08 | 1     | cn105            |

```
[usuario@leftraru1 ~]$ scancel 9142401
```

cancelar trabajo




# Directivas en SLURM

- -J example
- -p slims
- -n 20
- -c 20
- --ntasks-per-node=20
- -o file
- -e file
- --mail-user=user@gmail.com
- --mail-type=ALL



# Arquitectura de Memoria Compartida y Distribuida



# Ejercicio 1

- Lanza en la partición *slims* de Leftraru ejecutando el comando **hostname** con **srun**:
  - Con 1 único proceso.
  - Con 2 procesos iguales.
  - Con 2 procesos iguales en distintos nodos.
  - Lanzando un proceso que tenga dos *cores* reservados.
- Anota cada uno de los comandos ejecutados y la salida de los mismos.
- En la partición *slims* ¿cuántos *cores* puedes reservar por proceso? ¿Por qué es ese número? ¿Es igual en la partición *general*? ¿Qué ocurre si reservas más *cores* de los disponibles?
- ¿Qué ocurre si no especificas la partición al ejecutar?



# SBATH Ejemplo de script básico test.sh

Utilizar su editor por consola preferido: vim, nano

```
#!/bin/bash
#SBATCH -J ejemplo
#SBATCH -p slims
#SBATCH -n 1
#SBATCH -o archivo_%j.out
#SBATCH -e archivo_%j.err
#SBATCH --mail-user=usuario@gmail.com
#SBATCH --mail-type=ALL
```

```
sleep 10
```

Ejecución:  
sbatch test.sh



# Comandos útiles - Consultar información job

```
[root@leftraru1 ~]# scontrol show job 9160565
```

```
JobId=9160565 JobName=w.fepc-f-cnt-oo.m2
```

```
UserId=worellana(1194) GroupId=fisica_unab(1141) MCS_label=N/A
```

```
Priority=109951 Nice=0 Account=unab QOS=120
```

```
JobState=RUNNING Reason=None Dependency=(null)
```

```
Requeue=0 Restarts=0 BatchFlag=1 Reboot=0 ExitCode=0:0
```

```
RunTime=04:28:03 TimeLimit=3-00:00:00 TimeMin=N/A
```

```
SubmitTime=2017-10-09T11:25:36 EligibleTime=2017-10-09T11:25:36
```

```
StartTime=2017-10-09T15:04:40 EndTime=2017-10-12T15:04:40
```

```
Deadline=N/A
```

```
PreemptTime=None SuspendTime=None SecsPreSuspend=0
```

```
Partition=slims AllocNode:Sid=leftraru4:52235
```

```
ReqNodeList=(null) ExcNodeList=(null)
```

# Ejercicio 2

- Crea un *script* de ejecución para lanzarlo con **sbatch**, con las siguientes consideraciones:
  - La partición a lanzar es *slims*.
  - Reserva un único *core*.
  - Ejecuta el comando **stress -c 1**.
- Anota el *script* que has usado.
- El comando **stress** sirve para poner a prueba los distintos componentes de un computador. En este ejemplo estamos pidiendo usar una *CPU* (al 100%) durante un tiempo ilimitado. Ya que no se le ha especificado al comando un tiempo de término, en principio, la tarea no debiera terminar nunca. En relación a esto:
  - ¿Cuánto tiempo estará la tarea corriendo hasta que sea cancelada por el sistema?
  - ¿Qué comando debes de usar para obtener información sobre un trabajo que ya está corriendo?
  - ¿Qué comando puedes usar para obtener información acerca de las particiones?
  - Cancela la tarea. ¿Qué comando/s has usado para cancelarla?



# Slurm: Monitorear mis tareas desde consola

Monitorear desde la consola:

```
[usuario@leftraru1 ~]$ squeue
```



| JOBID   | PARTITION | NAME    | USER    | ST | TIME | NODES | NODELIST(REASON) |
|---------|-----------|---------|---------|----|------|-------|------------------|
| 4400799 | slims     | example | usuario | R  | 0:00 | 1     | cn042            |


Obtener el nombre de el/los nodos y visitar:

<http://dashboard.nlhpc.cl>

<http://monitor.nlhpc.cl/ganglia>



# Ganglia - monitor.nlhpc.cl



# Monitorear Job - *htop*

Puede ingresar a través de ssh a un nodo en donde tenga una tarea en ejecución y ejecutar **htop**

```
1 [|||||100.0%] 6 [ 0.0%] 11 [ 0.0%] 16 [ 0.0%]
2 [ 0.0%] 7 [ 0.0%] 12 [ 0.0%] 17 [ 0.0%]
3 [|||||100.0%] 8 [ 0.0%] 13 [ 0.0%] 18 [ 0.0%]
4 [ 0.0%] 9 [ 0.7%] 14 [ 0.0%] 19 [ 0.0%]
5 [ 0.0%] 10 [ 0.0%] 15 [ 0.0%] 20 [ 0.0%]

Mem[||||| 1.56G/62.7G] Tasks: 44, 39 thr: 3 running
Swp[ 0K/62.5G] Load average: 2.00 2.01 2.05
Uptime: 4 days, 00:36:11

  PID USER      PRI  NI  VIRT   RES   SHR  S  CPU% MEM%   TIME+  Command
18305 nperinet    20   0 19020  3768   892  R 100.0  0.0 2h52:34 ./LL_RK4.x
18335 nperinet    20   0 17104  1584   892  R 100.0  0.0 2h47:30 ./LL_RK4.x
18605 root        20   0 121M   2432  1476  R  0.0  0.0 0:00.05 htop
   1 root        20   0 185M   5068  2384  S  0.0  0.0 0:11.06 /usr/lib/systemd/systemd --switched-root --system --de
  669 root        20   0 112M   2000  1564  S  0.0  0.0 0:00.00 /bin/bash
  671 root        20   0 36816  7236  6908  S  0.0  0.0 0:00.78 /usr/lib/systemd/systemd-journald
  726 root        20   0 43808  2428  1268  S  0.0  0.0 0:00.83 /usr/lib/systemd/systemd-udev
1012 root        16  -4 51188  1620  1236  S  0.0  0.0 0:00.05 /sbin/auditd -n
1002 root        16  -4 51188  1620  1236  S  0.0  0.0 0:00.25 /sbin/auditd -n
1206 root        20   0 448M  10956  6968  S  0.0  0.0 0:00.00 /usr/sbin/NetworkManager --no-daemon
1209 root        20   0 448M  10956  6968  S  0.0  0.0 0:00.09 /usr/sbin/NetworkManager --no-daemon
1139 root        20   0 448M  10956  6968  S  0.0  0.0 0:02.34 /usr/sbin/NetworkManager --no-daemon
1144 avahi        20   0 30220  1564  1300  S  0.0  0.0 0:00.44 avahi-daemon: running [cnf004.local]
1148 dbus        20   0 28824  1772  1352  S  0.0  0.0 0:00.44 /bin/dbus-daemon --system --address=systemd: --nofork
1166 root        20   0 198M  1236   776  S  0.0  0.0 0:00.00 /usr/sbin/gssproxy -D
1167 root        20   0 198M  1236   776  S  0.0  0.0 0:00.00 /usr/sbin/gssproxy -D
1168 root        20   0 198M  1236   776  S  0.0  0.0 0:00.00 /usr/sbin/gssproxy -D
1169 root        20   0 198M  1236   776  S  0.0  0.0 0:00.00 /usr/sbin/gssproxy -D
1170 root        20   0 198M  1236   776  S  0.0  0.0 0:00.00 /usr/sbin/gssproxy -D
1164 root        20   0 198M  1236   776  S  0.0  0.0 0:00.30 /usr/sbin/gssproxy -D

F1Help F2Setup F3Search F4Filter F5Free F6SortBy F7Nice F8Nice F9Kill F10Quit
```

# Ejercicio 3


- Crea un *script* de ejecución para lanzarlo con **sbatch**, con las siguientes consideraciones:
  - La partición a lanzar es *slims*.
  - Reserva un nodo completo.
  - Ejecuta el comando **stress -c 40 -t 15m**.
- Anota el *script* que has usado.
- ¿Cuántos recursos de *CPU* estás usando? Muestra una captura de pantalla que muestre gráficamente lo que ocurre con la carga de *CPU* en el nodo donde se está ejecutando la tarea.
- Entra al nodo donde se está ejecutando la tarea, ejecuta el comando **htop** e interpreta lo que está pasando.
- ¿Cuál sería la manera correcta de lanzar la ejecución para usar todos los cores disponibles en un nodo? Inserta en el informe una captura de pantalla que muestre gráficamente lo que ocurre con la carga de CPU en el nodo donde se está ejecutando la tarea.



# Reserva Memoria RAM

Límite en la memoria RAM:

- Por defecto se reserva 1GB de RAM por core reservado
- Si se excede se obtendrá el error: "Exceeded job memory limit"
- Reservar más RAM por *core* usado: `#SBATCH --mem-per-cpu=2400`
- Reservar más RAM por *job*: `#SBATCH --mem=48000`



Límites CPU:

- Se activa afinidad core/hilo

# Ejercicio 4

- Crea un *script* de ejecución para lanzarlo con **sbatch**, con las siguientes consideraciones:
  - La partición a lanzar es *slims*.
  - Reserva un único *core*.
  - Indica que envíe un correo cuando el *job* cambie de estado.
  - Ejecuta el comando **stress -m 1 --vm-bytes 2048M -t 15m**.
- Anota el *script* que has usado.
- ¿Qué está ocurriendo con la ejecución? ¿a qué se debe?
- Relanza la tarea modificando el *script* para poder ejecutar la tarea. Anota el *script*.
- ¿Cuántos recursos de RAM estás usando? Inserta en el informe una captura de pantalla que muestre gráficamente lo que ocurre con la carga de RAM en el nodo donde se está ejecutando la tarea.





# Sistema de Módulos

- Permite tener diferentes aplicaciones y versiones de estos en un mismo sistema operativo.
- En el NLHPC usamos **Lmod** (<https://github.com/TACC/Lmod>).
- El actual sistema de módulos está disponible para las distintas arquitecturas de procesador (AVX512,AVX,SSE4.2)

# Lmod: Buscar

```
eguerre@leftraru1:/home/eguerre$ ml spider Python
```

---

Python:

---

Description:

Python is a programming language that lets you work more quickly and integrate your systems more effectively.

Versions:

Python/2.7.15

Python/3.7.2

Python/3.7.3

Other possible modules matches:

Biopython IPython protobuf-python

---

To find other possible module matches execute:

```
$ module -r spider '.*Python.*'
```

---

For detailed information about a specific "Python" module (including how to load the modules) use the module's full name.

For example:

```
$ module spider Python/3.7.3
```

# Lmod: Cargar distintas versiones

```
eguerre@leftraru1:/home/eguerre$ ml Python/3.7.3
eguerre@leftraru1:/home/eguerre$ ml
```

Currently Loaded Modules:

```
1) GCCcore/8.2.0      4) impi/2019.2.187  7) intel/2019b 10) libreadline/8.0 13) SQLite/3.27.1 16) libffi/3.2.1
2) icc/2019.2.187-GCC-8.2.0-2.31.1 5) imkl/2019.2.187 8) bzip2/1.0.6 11) ncurses/6.1 14) XZ/5.2.4 17) Python/3.7.3
3) ifort/2019.2.187-GCC-8.2.0-2.31.1 6) binutils/2.32 9) zlib/1.2.11 12) Tcl/8.6.9 15) GMP/6.1.2
```

```
eguerre@leftraru1:/home/eguerre$ python -V
Python 3.7.3
```

```
eguerre@leftraru1:/home/eguerre$ ml Python/2.7.15
```

The following have been reloaded with a version change:

```
1) Python/3.7.3 => Python/2.7.15
```

```
eguerre@leftraru1:/home/eguerre$ ml
```

Currently Loaded Modules:

```
1) GCCcore/8.2.0      4) impi/2019.2.187  7) intel/2019b 10) libreadline/8.0 13) SQLite/3.27.1 16) libffi/3.2.1
2) icc/2019.2.187-GCC-8.2.0-2.31.1 5) imkl/2019.2.187 8) bzip2/1.0.6 11) ncurses/6.1 14) XZ/5.2.4 17) Python/2.7.15
3) ifort/2019.2.187-GCC-8.2.0-2.31.1 6) binutils/2.32 9) zlib/1.2.11 12) Tcl/8.6.9 15) GMP/6.1.2
```

```
eguerre@leftraru1:/home/eguerre$ python -V
Python 2.7.15
```

# Ejercicio 5

- Descarga el siguiente código: [n-queens-problem-3.py](#) en tu directorio de trabajo.
- Crea un *script* de ejecución para lanzarlo con **sbatch**, con las siguientes consideraciones:
  - La partición a lanzar es *slims*.
  - Cada *job* reserva un único *core*.
  - Supón que cada proceso ocupa 2400MB de memoria RAM.
  - Ejecuta el código con la versión de Python 3 más actualizada del sistema.
- Anota el *script* que has usado.
- Anota la salida de la ejecución.

# Eficiencia Computacional

- ¿Qué significa que mi programa escale?
  - Este concepto hace referencia a cómo se comporta un programa paralelo (más de una cpu) al aumentar el número de procesadores.
- Se dice que un sistema es escalable para un determinado rango de procesadores  $[1 \dots n]$ , si la eficiencia  $E(n)$  del sistema se mantiene constante y en todo momento por encima de un factor 0.5
- Normalmente todos los sistemas tienen un determinado número de procesadores a partir del cual la eficiencia empieza a disminuir o forma más o menos brusca
- ¿Por qué es importante conocer como escala mi programa?
  - En nuestra infraestructura, históricamente los usuarios suelen usar el máximo de cores que pueden solicitar. No obstante, una ejecución por ejemplo de 120 cores no tiene porqué ser dos veces más rápida que una de 60 cores

# Eficiencia Computacional - Speedup y Eficiencia

- Actualmente, para la solicitud de cuentas de investigación (superior a 88 cores) solicitamos un escalamiento de la aplicación con estas 2 métricas: Speedup y Eficiencia
- El speedup es la principal métrica que nos indica la ganancia que obtenemos mediante la paralelización:

$$Speedup = \frac{T_{original}}{T_{mejora}}$$

- La eficiencia es la métrica del uso de los recursos computacionales requeridos por la ejecución de un algoritmo en función del tamaño de las entradas. Se define como el cociente entre el speedup y el número de procesos en los que ejecutamos la aplicación

# Ejemplo de escalamiento

- El tiempo original de una aplicación que necesitamos escalar utilizando 1 core es de 5 segundos. Para calcular el speedup vamos incrementando los cores de acuerdo a la fórmula:

$$(1 \text{ core}) \frac{5}{5} = 1$$

$$(2 \text{ cores}) \frac{5}{2.5} = 2$$

$$(4 \text{ cores}) \frac{5}{2} = 2.5$$

$$(6 \text{ cores}) \frac{5}{1.66} = 3.01$$

$$(8 \text{ cores}) \frac{5}{1.25} = 4$$

$$(10 \text{ cores}) \frac{5}{1.2} = 4.16$$

$$(12 \text{ cores}) \frac{5}{1.18} = 4.23$$

$$(14 \text{ cores}) \frac{5}{1.18} = 4.23$$


$$(16 \text{ cores}) \frac{5}{1.18} = 4.23$$

- Llevando estos resultados a una tabla tenemos lo siguiente:

| Nº Cores   | 2    | 4    | 6    | 8    | 10   | 12   | 14   | 16   |
|------------|------|------|------|------|------|------|------|------|
| Tiempo     | 2.50 | 2.00 | 1.66 | 1.25 | 1.20 | 1.18 | 1.18 | 1.18 |
| Speedup    | 2.00 | 2.50 | 3.01 | 4.00 | 4.16 | 4.23 | 4.23 | 4.23 |
| Eficiencia | 1.0  | 0.6  | 0.5  | 0.5  | 0.4  | 0.3  | 0.3  | 0.2  |

# Ejemplo de escalamiento

- Dado que la eficiencia debe ser mayor a 0.5, el número de cores a solicitar debería ser a lo sumo 4. De hecho no se deberían seguir lanzando ejecuciones a partir de 6 cores, dónde se ve que la eficiencia es igual (o inferior) a 0.5:





# Ejercicio 6

- Imagina que deseas ejecutar el programa **namd**.
  - ¿Qué opciones tienes disponibles en la infraestructura del NLHPC?
  - ¿Qué diferencias hay entre ellas?
  - Si quieres lanzar usando GPUs, ¿qué módulos debes de cargar?
- Anota los comandos que has usado.

# Otros Comandos - Consultar espacio usado

```
[root@leftraru1 ~]# lfs quota -hu $USER /home
```

Disk quotas for user USER (uid 1000):

| Filesystem | used          | quota | limit      | grace | files | quota | limit | grace |
|------------|---------------|-------|------------|-------|-------|-------|-------|-------|
| /home      | <b>4.994G</b> | 0k    | <b>80G</b> | -     | 57294 | 0     | 0     | -     |

# Gracias!

<https://www.nlhpc.cl/>