

# Introducción a Slurm

Alfonso Pardo

[alfonso.pardo@ciemat.es](mailto:alfonso.pardo@ciemat.es)

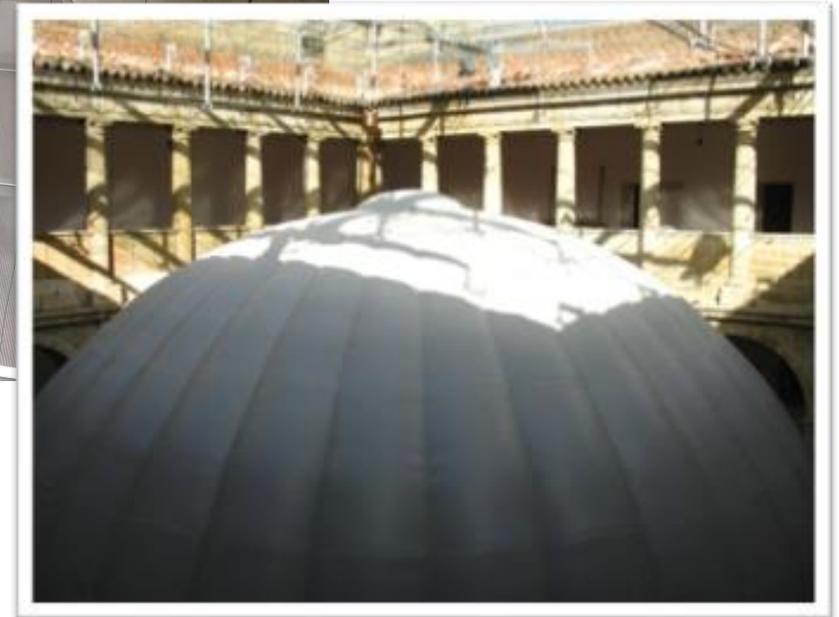
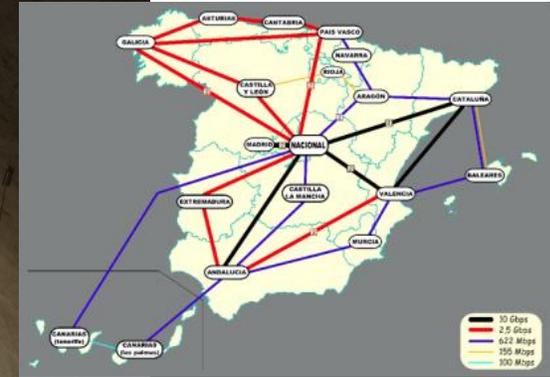
# ¿Quiénes somos?



San Francisco Convent



# ¿Quienes somos?



# ¿Quiénes somos?

- Centro de datos del CIEMAT (MICINN), iniciativa conjunta con la Junta de Extremadura.
- Institución pública, financiada por PGE y FEDER.
- Misión: Consolidar y diseminar eCiencia y TICs, especialmente Grid y eInfraestructuras.
- Ofrecer nuestros recursos: Grid, Cloud y HPC (GPU, clusters, ...).
- Contribuir a la expansión efectiva de eCiencia.
- Facilitar el uso de los recursos (nuevos sitios y nuevas aplicaciones).

# Nuestra infraestructura HPC/HTC

- **Computo:**
  - Para grid (HTC).
  - Para CPU/GPGPU (HPC)
- **Almacenamiento:**
  - Lustre
- **Red:**
  - Ethernet
  - Infiniband
  - Fibre channel
- **Free cooling**
- **Redundacia**



# Supercomputador

- **HPC:**

- **GPGPU:**

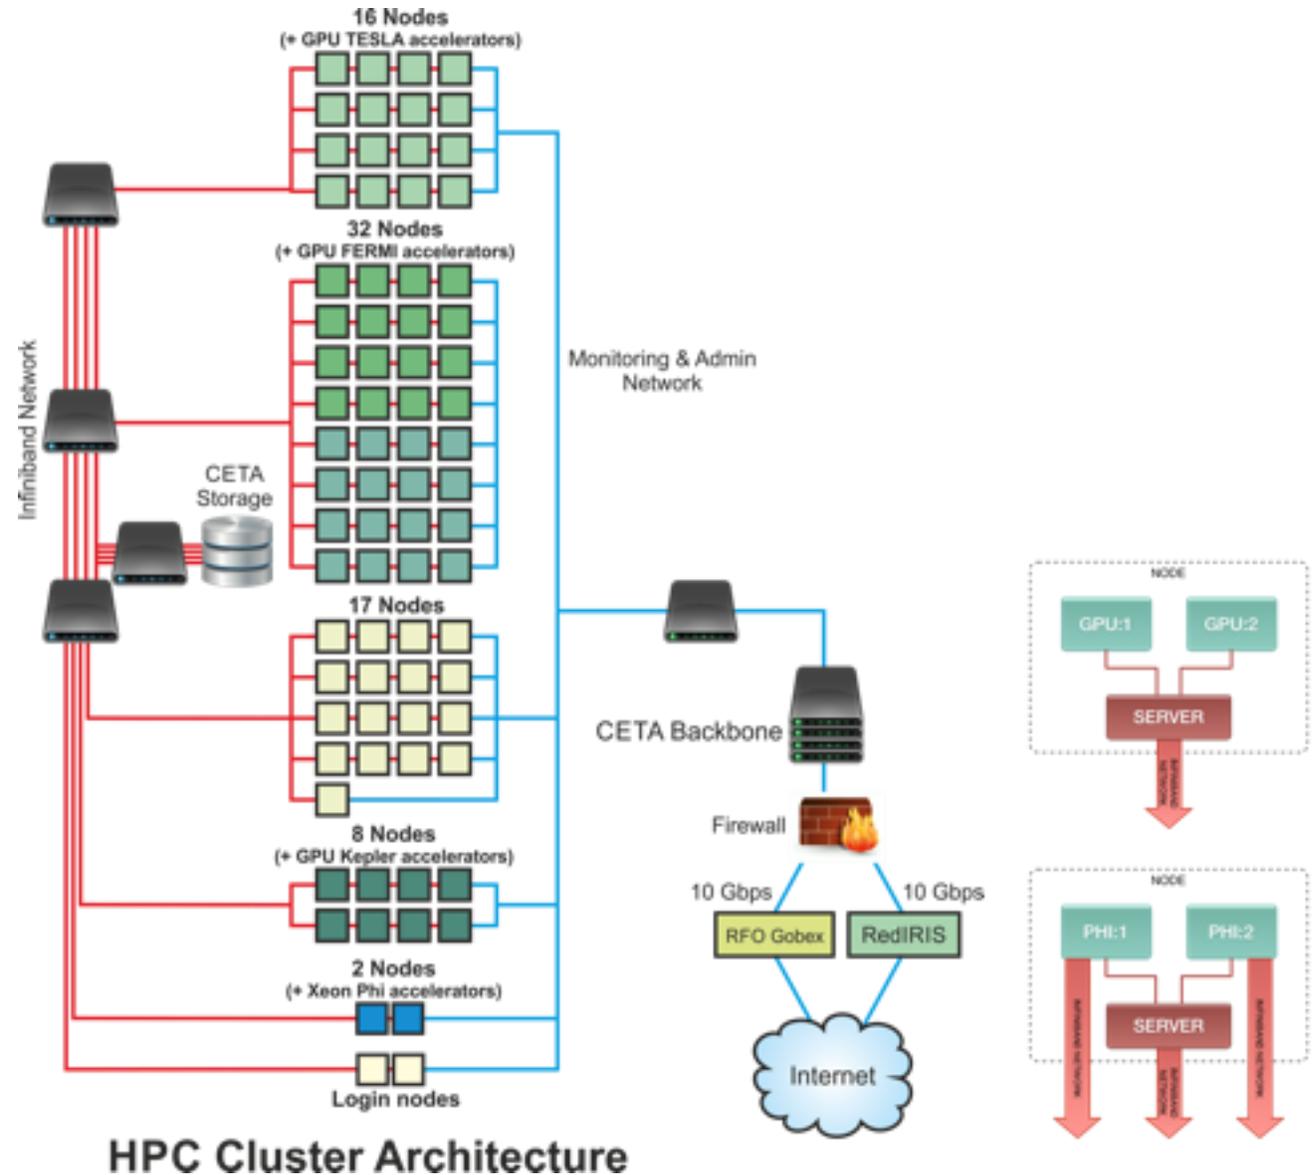
- 17 nodos x 2 TESLA
    - 32 nodos x 2 FERMI
    - 8 nodos KEPLER

- **PHI:**

- 2 nodos x 2 PHI

- **CPU:**

- 48 nodos



# Supercomputador

- **Almacenamiento:**

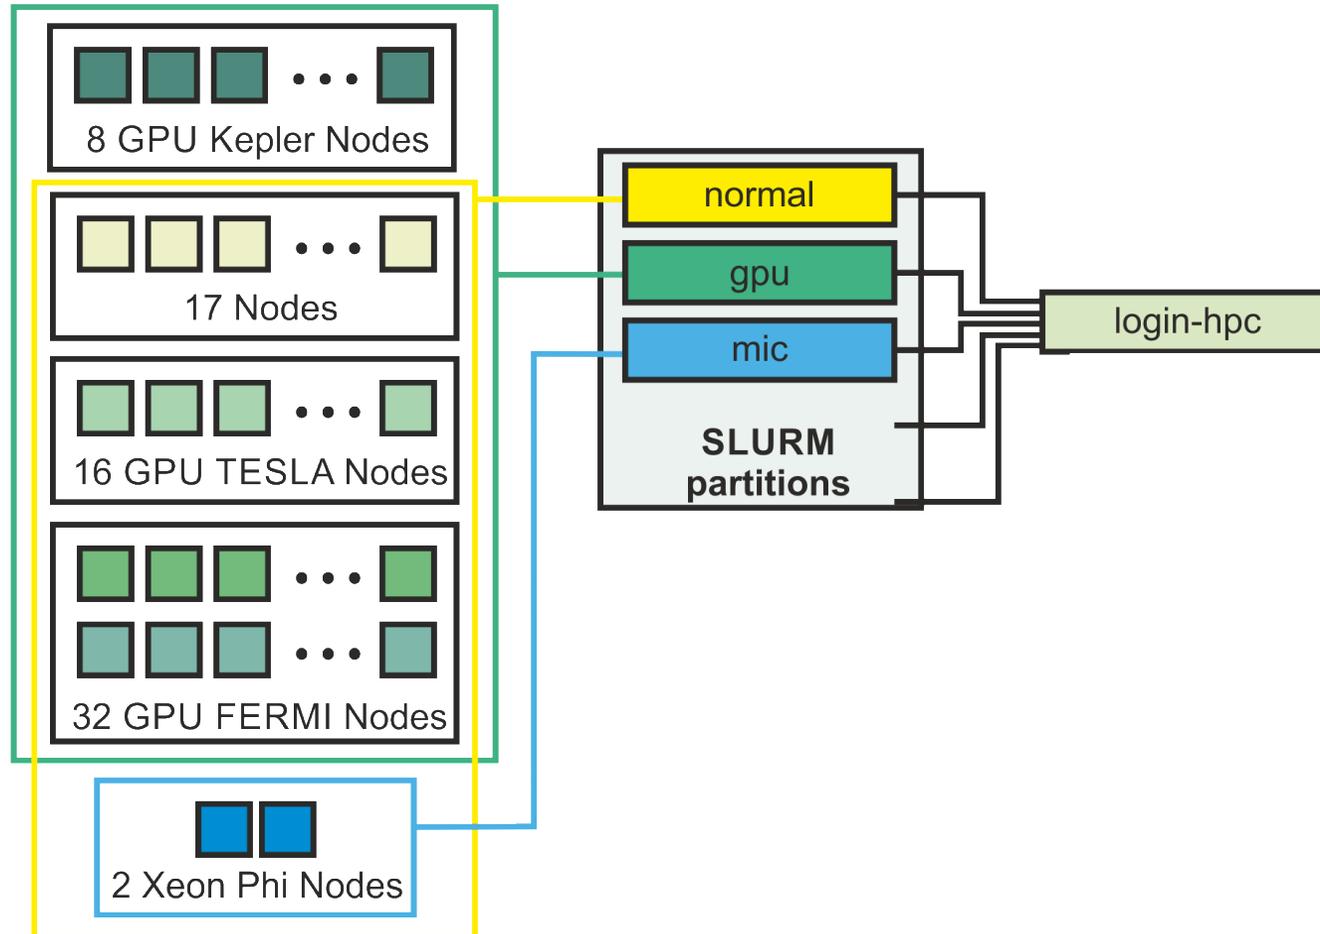
- 168TB+110TB+240TB
- 2 librerías de cintas / HSM
- CEPH (en progreso)

- **Network**

- 10 Gb Ethernet
- Conexión a RedIris Nova (10Gb/s)
- Conexión Infiniband en el cluster (40/50Gbs)
- Almacenamiento lustre por fibra (8Gbs) y SAS (6Gbs)



# Supercomputador

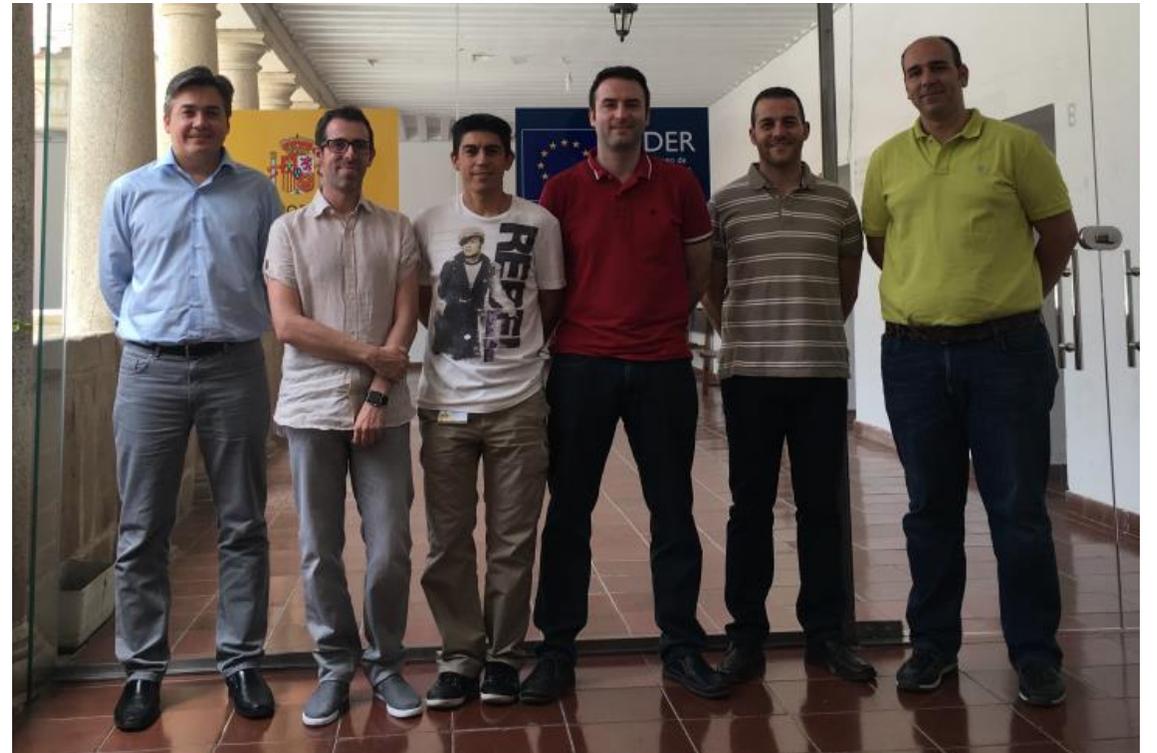


## Particiones (colas):

- normal: arquitectura x86 sin aceleradores, solo CPU.
- gpu: arquitectura x86 con aceleradores: Tesla, Fermi y Kepler.
- mic: arquitectura x86 con acelerador Xeon PHI.

# Supercomputador

- SO:
  - Centos 7.3
- Gestor de colas:
  - SLURM
- Conectividad:
  - Infiniband FDR+QDR (40/50Gbps en baja latencia)
  - Ethernet 1Gbs
- Almacenamiento:
  - Lustre
- Backup:
  - Bacula (Robot de cintas)
- Personal muy cualificado 😊



# ¿Que es Slurm?

- Gestor de colas mas utilizados (60% del Top500)
- Gratuito y open source
- Gran comunidad, grupo de usuarios
- Permite una gestión de trabajos completa:
  - Calidad de servicio
  - Colas (particiones)
  - Limites de recursos por usuario/grupo
  - Parametros de calidad de servicio
  - Reservas dinámicas
  - ...

# Introducción a SLURM

- Prioridades

- Cuando hay mas trabajos que nodos hay que establecer un método justo que determine cual es el próximo trabajo en ser despachado.
- SLURM realiza cálculos periódicamente basándose en un algoritmo de gestión de prioridades en base a varios parámetros configurables (por el administrador):
  - Tamaño del trabajo (numero de nodos/cores).
  - Duración de los Jobs (se especifica a la hora de encolarlo).
  - Edad del trabajo en la cola
  - Numero de trabajos en cola

# Introducción a SLURM

- ¿Como acceder?
  - Acceso por SSH al nodo de login.
  - Desde el nodo de login se ejecutan todos los comandos.
- Almacenamiento
  - El espacio de trabajo es compartido a todos los nodos en un sistema de ficheros paralelo y distribuido
- Librerías
  - Cada usuario necesita distintas librerías
  - Cada librería puede tener distintas versiones o “sabores”.
  - Cada librería puede tener distintas dependencias.
  - Cada librería puede tener distintas rutas de instalación.
  - Solución → “environment modules”
    - Permite gestionar diferentes versiones o sabores de un mismo compilador o librería en una misma instalación del sistema operativo.

# Introducción a SLURM

- Uso de módulos o librerías:
  - Como carga librerías mediante “módulos”
  - Permite cargar una librería y sus dependencias:
    - Carga openmpi → gcc
  - Permite varias versiones del mismo software.
  - No genera conflictos entre versiones.
  - El software está centralizado.
  - Se cargan las variables de entorno del módulo.
  - Se puede especificar versión para un mismo modulo. En el caso que se omita se carga la mas actual o la que este etiquetada por defecto.
  - Los módulos pueden tener etiquetas si son especiales o tienen alguna compilación especial:
    - (g) → compilada para GPU

# Uso de librerías

- Para cargar un módulo:

- `module avail` → muestra todos los nodos disponibles
- `module load <nombre_modulo>` → Carga un modulo
- `module list` → lista todos los módulos cargados
- `module unload` → quita un módulo previamente cargado
- `module purge` → elimina todos los modulos cargados

- Ejemplos:

- `module load intel` → Carga las librerías mas actual de intel y variables de entorno.
- `module load gcc/6.2.0` → Carga la librería gcc version 6.2 y sus variables de entorno.

# Comandos y envío de trabajos

- Comandos útiles:

- `sinfo` -> obtiene información de estado del supercomputador.
- `squeue` -> obtiene estado de las colas/particiones.
- `srun` -> ejecuta un trabajo simple.
- `sbatch` -> ejecuta un script.
- `scancel` -> cancela un trabajo lanzado.
- `sacct` -> obtiene estadísticas de uso del supercomputador.

- Parámetros:

- `-N X` → uso de “X” nodos
- `-n X` → lanza “X” instancias del trabajos
- `-p X` → usa la partición “X”
- `--gres=X:Y` → reserva para usar el Y recursos X
- `-t D-HH:MM:SS` → Tiempo máximo de ejecución de un trabajo en días, horas, minutos y segundos.

# Comandos y envío de trabajos

- Envío de trabajos:
  - Uso básico:
    - `sbatch <parametros> <script>`
  - El script contiene:
    - Variables de entorno
    - Llamada al programa
  - Para este curso se han reservado nodos para no tener que esperar a otros usuario:
    - Parametro: `--reservation=curso_ciemat00_13`
- Obtención de resultados:
  - Una vez ejecutado el trabajo, si ha finalizado con éxito obtendremos dos ficheros:
    - `slurm-XXXXXX.out` → Contiene los resultados de la ejecución del trabajos lanzado.
    - `slurm-XXXXXX.err` → Contiene los errores de la ejecución del trabajo lanzado.

# Comandos y envío de trabajos

- Parámetros mas usuales para envío de trabajos:

Parámetro	Abreviatura	Descripción
--partition=	-p	Particion a la que enviaremos el trabajo
--node=	-N	Numero de nodos requeridos
--ntask=	-n	Numero de tareas a enviar
--gres=	--gres	Uso de recurso: gpu,mic
--time=	-t	Tiempo máximo de la ejecución
--mem=		Memoria en megabits que usara nuestro trabajo
--job-name=	-J	Nombre de nuestro trabajo
--error=	-e	Fichero de salida de error
--output=	-o	Fichero de salida de resultados

Mas información:

- <https://slurm.schedmd.com/sbatch.html>
- man sbatch

# Comandos y envío de trabajos



- Estado del cluster:
  - Uso básico:
    - sinfo

```
PARTITION AVAIL  TIMELIMIT  NODES  STATE NODELIST
normal*    up    infinite   15   resv bc[10-14],bd[16-25]
normal*    up    infinite   62   alloc bc[03-09,15-18],bd[01-14,26-28],be[01-02],dap[101-104,201-204,301-304,401-404,501-504,601-604,701-704,801-804]
normal*    up    infinite    5   idle bd[15,29-32]
mic        up    infinite    2   alloc be[01-02]
gpu        up    infinite   15   resv bc[10-14],bd[16-25]
gpu        up    infinite    2   mix  da[09,11]
gpu        up    infinite   28   alloc bc[03-09,15-18],bd[01-14,26-28]
gpu        up    infinite   11   idle bd[15,29-32],da[10,12-16]
```

- Uso detallado:
  - avail nodes

```
NODELIST          NODES  CPUS  MEMORY AVAIL_FEATURES          GRES
bd[17-32]         16    12   22000  Infiniband_QDR,CPU_Westmere,E5649,2.53GHz,24GB_RAM,gpu_fermi_M2075  gpu:fermi2070:2
bc[03-18]         16     8   22000  Infiniband_QDR,CPU_Nehalem,E5520,2.26GHz,24GB_RAM,gpu_tesla_C1060    gpu:tesla:2
bd[01-16]         16     8   22000  Infiniband_QDR,CPU_Nehalem,E5520,2.26GHz,24GB_RAM,gpu_tesla_C2050    gpu:fermi2050:2
be[01-02]         2     12  30000  Infiniband_QDR,CPU_Sandy,E5-2620,2.00GHz,32GB_RAM,phi                mic:2,rapl:1
dap[101-104,201-204,301-304,401-404,501-504] 32    12   30000  Infiniband_QDR,CPU_Sandy,E5-2620,2.00GHz,32GB_RAM                    rapl:1
da[09-16]         8     24  62000  Infiniband_FDR,CPU_Haswell,E5-2680v3,2.50GHz,64GB_RAM,gpu_kepler_K80  gpu:kepler:2,rapl:1
```

# Comandos y envío de trabajos



- Estado de las colas:
  - Uso básico:
    - squeue
  - Solo mis trabajos
    - squeue -u nombre\_usuario
  - Uso detallado
    - squeue -l

JOBID	PARTITION	NAME	USER	ST	TIME	NODES	NODELIST(REASON)
37806	normal	barrido.	apardo	PD	0:00	1	(Resources)
37807	normal	barrido.	apardo	PD	0:00	1	(Priority)
37808	normal	barrido.	apardo	PD	0:00	1	(Priority)
37809	normal	barrido.	apardo	PD	0:00	1	(Priority)
37810	normal	barrido.	apardo	PD	0:00	1	(Priority)
37801	normal	barrido.	apardo	R	0:02	1	bd31
37802	normal	barrido.	apardo	R	0:02	1	bd29
37803	normal	barrido.	apardo	R	0:02	1	bd30
37804	normal	barrido.	apardo	R	0:02	1	bd32
37805	normal	barrido.	apardo	R	0:02	1	bd15

# Comandos y envío de trabajos

- Estadísticas de uso:
  - Uso básico:
    - `sacct`
  - Si no especificas tiempo solo muestra el día actual.
  - Para crear un rango de tiempo de estadísticas usar los parámetros “-S” y “-E” para determinar el inicio (S) y fin (E).
    - Emplearemos la notación: YYYY-MM-DD
    - `sacct -S 2017-01-01 -E 2017-10-09`
- O ver el estado concreto de un trabajo con “-j numero\_trabajo”

JobID	JobName	Partition	Account	AllocCPUS	State	ExitCode
24445	mpicuda.sh	gpu	ursos	1	COMPLETED	0:0
24445.batch	batch		ursos	1	COMPLETED	0:0
24445.0	mpicuda		ursos	1	COMPLETED	0:0
26092	deviceQue+	gpu	ursos	1	COMPLETED	0:0
26092.batch	batch		ursos	1	COMPLETED	0:0

# Comandos y envío de trabajos

Code	State	Description
CA	CANCELLED	Trabajo cancelado por el usuario o el administrador.
CD	COMPLETED	El trabajo ha finalizado en todos los nodos
CF	CONFIGURING	El trabajo ha ocupado los recursos y esta esperando que estos terminen de iniciarse.
CG	COMPLETING	El trabajo finalizado, se esta esperando por algún nodo.
F	FAILED	El trabajo ha finalizado con una condición distinta de 0 (éxito)
NF	NODE_FAIL	El trabajo ha finalizado porque algun nodo ha fallado.
PD	PENDING	El trabajo esa pendiente de los recursos.
R	RUNNING	Trabajo en ejecución.
S	SUSPENDED	El trabajo ha encontrado recursos, pero la ejecucion no se ha completado.
TO	TIMEOUT	El trabajo ha alcanza el tiempo limite..

# Comandos y envío de trabajos



- Estado de las particiones:
  - Uso:
    - avail partitions

```
PARTITION AVAIL  TIMELIMIT  NODES(A/I/O/T)  NODELIST
normal*    up        infinite    62/20/0/82     bc[03-18],bd[01-32],be[01-02],dap[101-104,201-204,301-304,401-404,501-504,601-604,701-704,801-804]
mic        up        infinite    2/0/0/2        be[01-02]
gpu        up        infinite    30/26/0/56     bc[03-18],bd[01-32],da[09-16]
```

# Prioridades

- Determina en que posición de la cola se situara un trabajo para ser atendido.
- Factores que determinan prioridad de tarea
  - Edad - la cantidad de tiempo que el trabajo ha estado esperando en la cola
  - Tamaño de la tarea - número de nodos solicitados por el trabajo
  - Partición - prioridad para una partición determinada
  - Mientras más tareas se ejecuten en el cluster, menor será la prioridad.
  - Mientras menos tareas se ejecuten en el clúster, más alta es la prioridad.

# Comandos y envío de trabajos



- Ejemplo:

- Script (hostname.sh):

```
#!/bin/sh  
hostname
```

- Ejecucion:

- `sbatch -n 2 --reservation=curso_ciemat00_13 -t 0-00:01:00  
hostname.sh`

- Resultado?

# Comandos y envío de trabajos



- Ejemplo:
  - Script (holamundo.sh):

```
#!/bin/bash
./holamundo_app.sh
```
  - Script (holamundo\_app.sh):

```
#!/bin/bash
yo=$(hostname)
echo "Hola mundo desde $yo"
```
  - Ejecución:
    - `chmod +x holamundo_app.sh`
    - `sbatch -n 2 --reservation=curso_ciemat00_13 -t 0-00:01:00 ./holamundo.sh`
- Resultado?

# Comandos y envío de trabajos

- Slurm permite enviar y administrar miles de trabajos similares de una sola vez.
  - Todos los trabajos deben tener las mismas condiciones iniciales.
  - Provee de variables para controlar la ejecución de los jobs.



```
#!/bin/bash
#SBATCH --job-name=sleep-test
#SBATCH --partition=normal
#SBATCH -n 1
#SBATCH --output=st_%j.out
#SBATCH --error=st_%j.err
#SBATCH --array=1-10
#SBATCH -t 0-00:05:00

./ejecutable entrada_${SLURM_ARRAY_TASK_ID}
```

Sesión practica

