

## Políticas de gestión de colas

### Introducción

Hasta la actualización del supercomputador en diciembre de 2017 el sistema de gestión de los trabajos en las colas de ejecución se basaba únicamente en el orden de petición al sistema. Es decir, el trabajo solicitado en primer lugar era el primer trabajo en ejecutarse. Mientras hubiera recursos disponibles, las peticiones iban ejecutándose. Si todos los recursos del supercomputador estaban asignados a peticiones en ejecución, las siguientes peticiones quedaban pendientes a la espera de tener recursos disponibles.

Este sistema de trabajo al principio era suficiente, dado que el número de usuarios del clúster era bajo y no había interferencias notables.

Sin embargo, al aumentar el número de usuarios, así como el número de trabajos lanzados, se vio la necesidad de modificar esta política de gestión de recursos para evitar que un usuario colapsase el supercomputador y que el uso de los recursos fuese más equitativo entre todos los usuarios.

Es por ello que se ha puesto en marcha un sistema de priorización basado en varios factores que se explicará en los siguientes apartados. También, y por la misma razón se han establecido algunas limitaciones en las peticiones que admitirá el cluster.

### Recursos desde el punto de vista de la gestión de trabajos

En el presente documento, y en general siempre que hablemos de supercomputación, se entiende por recurso cualquier elemento del sistema susceptible de ser usado por un trabajo de modo que, durante su uso, cualquier otro trabajo no pueda disponer de él.

Entre estos recursos nos encontramos con los siguientes:

- Unidades de cómputo (núcleos, CPU, ... ).
- Tiempo de ejecución, medido en segundos de CPU.
- Memoria principal.
- GPU. Procesadores gráficos especializados en cálculos matriciales.
- Licencias de programas.

La lista puede ser mayor, pero los mostrados aquí son los principales.

### Colas de ejecución

Nuestro clúster cuenta con dos tipos de nodos. La principal diferencia entre ambos es que el segundo tipo cuenta con tarjetas gráficas *nVidia Tesla K20m* que pueden ser usadas por programas especializados que hacen uso intensivo de cálculos matriciales.

Dado que este segundo grupo solo cuenta con dos nodos especializados, se ha decidido crear, y mantener separadas, dos colas:

- La cola *cn* que agrupa a los otros 48 nodos para cálculos que no requieren las GPUs.
- La cola *gn* que reúne los dos nodos restantes para cálculos que sí requieran el uso de GPUs.

Por *defecto* los trabajos irán a la primera cola y, si alguien necesita el uso de GPUs, puede indicarlo con la opción correspondiente.

### Prioridad multifactor

Después de estudiar los distintos factores aplicables a la prioridad de los trabajos en cola, se llegó a la conclusión de que los factores, y sus pesos relativos, deberían ser los siguientes:

- *Tamaño del trabajo*. Entendido como tal el número de recursos de cualquier tipo solicitados para el mismo. En general se tiende a favorecer los trabajos pequeños que acaban pronto. Su peso relativo es de 1.

- **Edad del trabajo**. Entendida como tal el tiempo que el trabajo lleva en cola sin haber sido ejecutado. A medida que pasa más tiempo, mayor será la prioridad asignada por este factor. Su peso relativo es de 5.
- **Fair-share**. Este factor es una medida de los recursos solicitados recientemente. A medida que se solicitan más recursos, menor es este factor, favoreciendo así que otros usuarios puedan lanzar sus propios trabajos. Su peso relativo es de 10.

Para calcular la prioridad resultante para un trabajo se multiplicaría cada factor por su peso y se sumarían los tres valores, obteniéndose así la prioridad del trabajo.

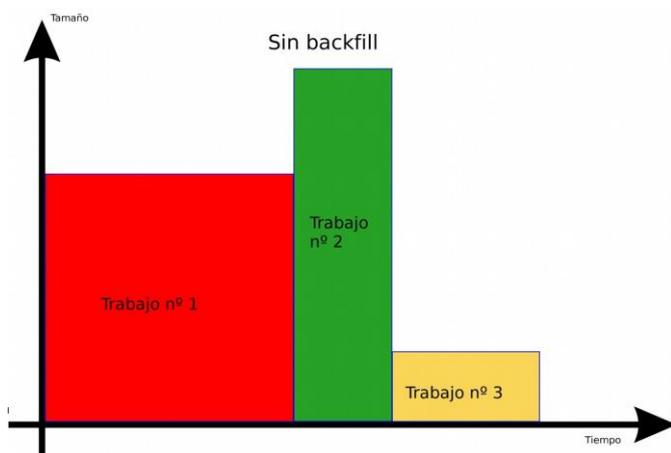
### Backfill

Independientemente de lo expuesto arriba, se puede activar (actualmente lo está) el mecanismo de backfill, según el cual si un trabajo de menor prioridad puede saltarse la cola sin afectar por ello a los que están por delante de él, el sistema lo adelantará.

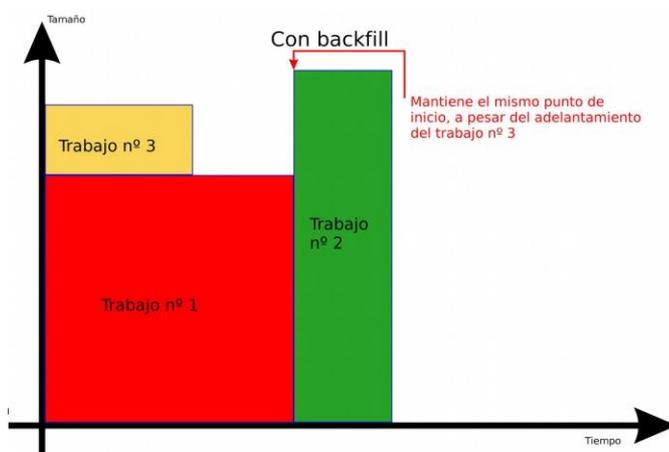
Ejemplo:

Veamos una cola de trabajos gestionada sin backfill. En la imagen, en el eje de abscisas se representa el tiempo y en el de ordenadas el tamaño del trabajo.

Mientras el trabajo n.º 1 está en ejecución llega el trabajo n.º 2 que, al no haber en el espacio libre, se queda en cola. El trabajo n.º 3 que viene detrás tendrá que esperar a que termine el n.º 2 a pesar de que sí cabría en el hueco.



En el caso de tener los mismos trabajos, pero con la cola usando el mecanismo de backfill, el trabajo n.º 3 se adelantaría y empezaría su ejecución inmediatamente.



### Condicionantes en el envío de peticiones

Para que el sistema de gestión de trabajos funcione de una manera adecuada, nos hemos visto obligados a imponer unos condicionantes al envío de los trabajos que se detallan a continuación:

- Tiempo de ejecución por defecto. Anteriormente el sistema tenía definida una duración por defecto de INFINITO, lo cual no es bueno para el sistema de backfill, ya que así el sistema no sabe cuándo terminarán los procesos y no podrá adelantar los trabajos más pequeños. Se establece por defecto en 48 horas. Así mismo se ha establecido una duración máxima de 30 días.
- Debido a incidentes por el envío masivo de trabajos que saturaron las colas de Slurm, se ha puesto una limitación de 192 CPUs (25% del cluster) simultáneos por persona junto con una limitación de 384 CPUs (50% del cluster) por grupo.
- También se ha establecido un límite de 300 trabajos que se pueden enviar simultáneamente por persona y de 1000 por grupo. Dicho límite engloba tanto a trabajos en estado RUNNING (en ejecución) como a trabajos en estado PENDING (esperando su inicio).

En el caso de que sea necesario utilizar unos límites superiores a los especificados, podrá solicitarse mediante un [CAU](#) dicha ampliación, exponiendo los motivos que sustentan dicha petición.

Desde el Área de Sistemas de la Información vigilamos porque el uso del cluster sea lo más satisfactorio posible para todos los usuarios. Por eso, y para evitar posibles problemas, es posible que la lista de condicionantes se vea ampliada o modificada en el futuro, con lo que actualizaríamos la lista aquí mostrada.