

Χρήση του  
ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

# Χρήση του ARIS

Δρ. Δημήτρης Ντελλής

GRNET

ntell [at] grnet.gr

Χρήση του  
ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

## Περιεχόμενα

- Σύνδεση στο σύστημα
- Σύστημα αρχείων
- Software Environment
  - Environment Modules
  - Διαθέσιμα πακέτα
- Batch System
- Βέλτιστες Πρακτικές Χρήσης - Συνηθισμένα Λάθη/Προβλήματα.

Χρήση του  
ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

- Σύνδεση στο σύστημα

- Δύο από τους κόμβους υπηρεσιών έχουν διαμορφωθεί σε login nodes
- Πανομοιότυπη εγκατάσταση, κοινοί λογαριασμοί χρηστών, κοινή πρόσβαση στο GPFS (/users και /work)
- Διεύθυνση και για τους 2 login nodes:  
**login.aris.grnet.gr**
- Σύνδεση με SSH με χρήση κλειδιού.

## Χρήση του ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

- Ταυτοποίηση χρήστη
  - password authentication
  - public key authentication
- Στο ARIS θα χρησιμοποιείται μόνο η δεύτερη μέθοδος
- Ζεύγος κλειδιών, public και private
- Το public ssh key αποθηκεύεται στον ssh server (login node στην περίπτωση μας) στο Home του χρήστη
- Το private ssh key βρίσκεται στον ssh client (π.χ. το laptop σας) και είναι **μυστικό!** Μόνο ο ιδιοκτήτης του πρέπει να έχει πρόσβαση σε αυτό.
- Το private ssh key μπορεί προαιρετικά να προστατεύεται με ένα passphrase

## ● Λογισμικό SSH Client

- Mac OS, Linux: OpenSSH, συνήθως υπάρχει εγκατεστημένο
  - **ssh** : SSH client, με αυτό θα συνδεθείτε
  - **ssh-keygen**: Δημιουργία, μετατροπή κλειδιών
  - **scp, sftp**: Μεταφορά αρχείων
- Windows: PuTTY (δωρεάν)
  - **PuTTY** : SSH client, με αυτό θα συνδεθείτε
  - **PuTTYgen** : Δημιουργία, μετατροπή κλειδιών
  - **PSCP, PSFTP** : Μεταφορά αρχείων
  - **putty-0.65-installer.exe** : Windows installer που εγκαθιστά όλα τα παραπάνω
- Windows: Bitvise (δωρεάν, με πολλές γραφικές διευκολύνσεις)

Χρήση του  
ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

- Δημιουργία ζεύγους ssh κλειδιών σε Mac OS, Linux
  - **ssh-keygen -t rsa -b 2048**
  - public key: `~/.ssh/id_rsa.pub`
  - private key: `~/.ssh/id_rsa`

- X Server for windows

- Χρήσιμος για εκτέλεση διάφορων εφαρμογών όπως profilers
- Xming X Server for Windows
- <http://sourceforge.net/projects/xming/>
- Για να δουλέψει, απαραίτητο να έχετε ενεργό το "Enable X11 forwarding"
- Το Xming πρέπει να τρέχει στο Windows PC σας πριν ξεκινήσετε κάποια γραφική εφαρμογή στο [login.aris.grnet.gr](http://login.aris.grnet.gr)

- Τι χρειάζεται να μας στείλετε για να αποκτήσετε πρόσβαση στο ARIS
  - Επιθυμητό username
  - Το ssh public key σας
  - Η διεύθυνση ή οι διευθύνσεις IP από όπου θα συνδέεστε, ώστε να επιτραπεί η πρόσβαση στο firewall του ARIS
  - Παραδείγματα
    - Η IP του υπολογιστή σας στο εργαστήριο σας
    - Εναλλάκτικά αν δεν έχετε σταθερό IP, ολόκληρο το υποδίκτυο του εργαστηρίου σας
    - Οι IP διευθύνσεις του VPN service του ιδρύματός σας



- Σύστημα αρχείων GPFS

- GPFS 4.1
- Δύο filesystems : /users και /work
- /users
  - Περίπου 250 TB
  - Applications
  - Home directories των χρηστών
  - Δεν πρέπει να εκτελούνται (τουλάχιστον I/O intensive) jobs στο Home
  - Μακροχρόνια αποθήκευση
- /work
  - Περίπου 450 TB
  - Για κάθε χρήση υπάρχει η μεταβλητή \$WORKDIR
  - Εδώ πρέπει να εκτελούνται τα jobs
  - Βραχυχρόνια αποθήκευση

## Environment Modules. Τι είναι ?

- Το πακέτο Environment Modules κάνει δυναμική τροποποίηση του περιβάλλοντος χρήστη μέσω των module files.
- Κύριες μεταβλητές περιβάλλοντος που προσαρμόζονται είναι οι PATH, MANPATH, και LD\_LIBRARY\_PATH, αλλά και μεταβλητές περιβάλλοντος που ενδεχομένως κάθε πακέτο λογισμικού χρειάζεται.
- Κάθε module file περιέχει την πληροφορία που χρειάζεται ώστε να ρυθμίσει τις μεταβλητές περιβάλλοντος για κάποια εφαρμογή.

- Όλα τα modules θέτουν μια μεταβλητή `MODULENAMEROOT`. Σε modules που αναφέρονται σε βιβλιοθήκες, συνήθως τα `include files` βρίσκονται στην `$MODULENAMEROOT/include` και οι βιβλιοθήκες στην `$MODULENAMEROOT/lib`
- Εάν υπάρχουν εξαρτήσεις ενός πακέτου λογισμικού από άλλα τα οποία επίσης ρυθμίζονται με `module file`, οι εξαρτήσεις αυτές μπορούν να περιγραφούν και εφόσον το αντίστοιχο `module` δεν είναι ενεργό είτε το φορτώνει είτε βγάζει μήνυμα λάθους ειδοποιώντας το χρήστη ότι πρέπει πρώτα να φορτώσει τις εξαρτήσεις.
- Σε περιπτώσεις πακέτων τα οποία υπάρχουν σε πάνω από μια έκδοση, υπάρχει ένα `module` για κάθε έκδοση και ο `administrator` μπορεί να ορίσει κάποια ως `default`.

## Environment Modules. Χρήση

- Έλεγχος πακέτων που είναι διαθέσιμα μέσω modules  
`module avail`  
ή  
`module -l avail`
- Έλεγχος ενεργών modules  
`module list`
- Απενεργοποίηση όλων των ενεργών modules  
`module purge`
- Απενεργοποίηση συγκεκριμένου module  
`module unload MODULENAME`

- Αλλαγή έκδοσης module

```
module switch MODULENAME/VER1 MODULENAME/VER2
```

- Πληροφορίες για το τι αφορά κάποιο module

```
module whatis MODULENAME/VERSION
```

- Κείμενο Βοήθειας για κάποιο module

```
module help MODULENAME/VERSION
```

- Για να δείτε τι κάνει η ενεργοποίηση ενός module

```
module show MODULENAME/VERSION
```

- Default version ενός module

- Όπως θα δείτε παρακάτω, σχεδόν όλα τα πακέτα που υπάρχουν στο ARIS σε πάνω από μια version έχουν μια από αυτές επισημασμένη ως default. Στην περίπτωση αυτή, οι εντολές

```
module load MODULENAME
```

και

```
module load MODULENAME/DEFAULTVERSION
```

είναι ισοδύναμες.

## Batch System

- Τι είναι ένα Batch System
  - Ένα Batch System ελέγχει την πρόσβαση στους διαθέσιμους υπολογιστικούς πόρους ώστε όλοι οι χρήστες να μπορούν να χρησιμοποιούν το σύστημα - Συνήθως σε ένα σύστημα υπάρχει μεγαλύτερη ζήτηση για πόρους από τους διαθέσιμους.
  - Δίνει τη δυνατότητα στο χρήστη να προδιαγράψει μια υπολογιστική εργασία (Job) , να την υποβάλει στο σύστημα και να αποσυνδεθεί από αυτό.
  - Η εργασία θα εκτελεστεί όταν υπάρχουν πόροι (cores, nodes, μνήμη) και χρόνος
- ARIS Batch System : SLURM, υποστηρίζεται PBS emulation

## Όταν μια εργασία υποβάλλεται σε ένα Batch system :

- Περιγράφονται οι πόροι που χρειάζεται το σύστημα (π.χ. cores, nodes, μνήμη, χρόνος εκτέλεσης)
- Το σύστημα καταγράφει τους πόρους που ζητήθηκαν
- Όταν βρεθούν οι διαθέσιμοι πόροι, ξεκινάει η εκτέλεση της εργασίας
- Οι πόροι μπορούν να χρησιμοποιηθούν όπως θέλει ο χρήστης
  - Ένα π.χ. MPI run (Η κύρια/προτεινόμενη χρήση)
  - Πολλά σειριακά runs : Αν και μπορεί να χρησιμοποιηθεί με αυτό τον τρόπο, ένα run δεν κερδίζει κάτι από την ύπαρξη π.χ. Infiniband.



## SLURM Scripts

Ένα SLURM Script περιγράφει τους πόρους που χρειάζεται για να τρέξει η εργασία, όπως επίσης τις εντολές εκτέλεσης της εργασίας.

Παρατηρήστε τους 2 τρόπους που μπορούν να περιγραφούν οι απαιτήσεις της εργασίας π.χ.

```
--nodes=200
```

και

```
-A sept2015
```

.

## SLURM Scripts

```
#!/bin/bash
#SBATCH --job-name="testSlurm" # Όνομα για διαχωρισμό μεταξύ jobs
#SBATCH --error=job.err.%j # Filename για το stderr
#SBATCH --output=job.out.%j # Filename για το stdout
# Το %j παίρνει την τιμή του JobID
# Αριθμός nodes
#SBATCH --nodes=200
# Αριθμός MPI Tasks
#SBATCH --ntasks=400
# Αριθμός MPI Tasks / node
#SBATCH --ntasks-per-node=2
# Αριθμός Threads / MPI Task
#SBATCH --cpus-per-task=10
# Μνήμη ανά node
#SBATCH --mem=56G
# Μνήμη ανά core
#SBATCH --mem-per-cpu=2800M
# Accounting tag (sept2015 για
# όλους στο training)
#SBATCH -A sept2015
# Ζητούμενος χρόνος HH:MM:SS
#SBATCH -t 01:00:00
# partition, default στο ARIS.
#SBATCH -p compute
module purge
module load gnu
module load intel
module load intelmpi

if [ x$SLURM_CPUS_PER_TASK == x ]; then
    export OMP_NUM_THREADS=1
else
    export OMP_NUM_THREADS=$SLURM_CPUS_PER_TASK
fi

srun EXECUTABLE ARGUMENTS
```

## SLURM Scripts

- Το script του προηγούμενου slide είναι η πλήρης περιγραφή μιας εργασίας.
- Μπορεί να υποβληθεί εργασία και με λιγότερα από τα #SBATCH directives
  - Δίνοντας μόνο το `--nodes` χωρίς το `--ntasks` το σύστημα μπορεί να υπολογίσει πόσα tasks θα χρησιμοποιήσει
  - Αντίστοιχα, δίνοντας μόνο το `--ntasks` το σύστημα μπορεί να υπολογίσει πόσα nodes χρειάζεται.
  - Τα υποχρεωτικά που σχετίζονται με τον αριθμό των cores που θα χρησιμοποιήσει μια εργασία είναι ένα από τα παραπάνω
  - Παραλείποντας το `--job-name`, το σύστημα το θέτει ίδιο με το όνομα του script.
  - Παραλείποντας το `--output` το σύστημα το θέτει σε `slurm-JOB_ID.out`
  - Υποχρεωτική είναι η χρήση του `--account` (ή `-A`)
  - Θέτοντας όλες τις μεταβλητές έχετε πλήρη έλεγχο του τι πόρους ζητάτε από το σύστημα.

## Χρήση **srun** για την εκτέλεση των εφαρμογών

- Οι εκδόσεις του MPI έχουν η κάθε μια ένα `mpirun`/`mpiexec` κλπ.
- Προτείνεται να χρησιμοποιείται το `srun` για την εκτέλεση παράλληλων εργασιών.
- Κάποιοι από τους λόγους
  - Το `srun` ξεκινάει τα εκτελέσιμα σε όλους τους κόμβους οπότε έχει πλήρη έλεγχο.
  - Το `srun` κάνει `accounting` κατανάλωσης ρεύματος, χρήση `Infiniband`, χρήση δίσκων, κλπ.
  - Είναι κοινός τρόπος για τις (3 προς στιγμήν) εκδόσεις MPI που υπάρχουν στο ARIS
  - Η χρήση `mpirun`, `mpiexec` κλπ. δεν συνίσταται. Σε περιπτώσεις που η εφαρμογή έχει προβλήματα και σταματήσει ίσως να παρουσιαστούν προβλήματα (`zombie procs`) στη χρήση του `scancel`.

## Επικοινωνία με το SLURM

- Υποβολή εργασίας  
`sbatch SLURM_JobScript.sh`  
Submitted batch job 15242
- Κατάλογος εργασιών  
`squeue`
- Κατάλογος εργασιών με περισσότερες λεπτομέρειες  
`squeue -o "%.8i %.9P %.10j %.10u %.8T %.5C  
%.4D %.6m %.10l %.10M %.10L %.16R"`
- Ακύρωση εργασίας  
`scancel JobID`
- Σε κάποιες περιπτώσεις που τα εκτελέσιμα δεν  
τερματίζονται άμεσα παίρνοντας SIGHUP από το  
SLURM  
`scancel -s KILL JobID`
- Εκτίμηση του πότε θα αρχίσει η εκτέλεση των εργασιών  
που είναι σε αναμονή για πόρους  
`squeue --start`
- Πληροφορίες για την τρέχουσα χρήση  
`sinfo`

## SLURM jobs dependency

- Εάν μια εργασία για να αρχίσει πρέπει κάποια άλλη να έχει ήδη αρχίσει ή τελειώσει, στο SLURM Script εκτός των άλλων :

```
#SBATCH --dependency=after:Job_ID
```

ή

```
#SBATCH --dependency=afterok:Job_ID
```

αντίστοιχα

- Εάν μια εργασία για να αρχίσει πρέπει κάποια άλλη με το ίδιο job name και χρήστη να έχει τελειώσει, στο SLURM Script εκτός των άλλων :

```
#SBATCH --dependency=singleton
```

- Εάν πρέπει μια εργασία να ξεκινήσει κάποιο συγκεκριμένο χρονικό διάστημα, στο SLURM Script εκτός των άλλων :
  - Έναρξη στις 16:00  
`#SBATCH --begin=16:00`
  - Έναρξη συγκεκριμένη ημέρα και ώρα :  
`#SBATCH --begin=2016-04-07T14:32:00`

Εάν κάποια εργασία δεν τρέχει και στο nodelist/REASON εμφανίζονται τιμές εκτός από nodenames ή Resources, τότε έχουμε ζητήσει περισσότερους πόρους από ότι μας επιτρέπεται

- `AssocMaxNodesPerJobLimit`  
Ζητάμε περισσότερα nodes από ότι επιτρέπεται στο account μας
- `AssocMaxWallDur`  
Ζητάμε περισσότερο χρόνο από ότι επιτρέπεται στο account μας
- Διάφοροι άλλοι λόγοι που εάν από το όνομα δεν είναι αντιληπτό, ανατρέξτε στο documentation του SLURM.



## SLURM Environment Variables

Όταν ξεκινάει η εργασία το SLURM βάζει κάποιες μεταβλητές που σχετίζονται με αυτή, και ενδεχομένως είναι χρήσιμες στον χρήστη.

<code>\$\$SLURM_NNODES</code>	# Αριθμός nodes
<code>\$\$SLURM_NTASKS</code>	# Αριθμός Tasks
<code>\$\$SLURM_NPROCS</code>	# " " "
<code>\$\$SLURM_NTASKS_PER_NODE</code>	# Αριθμός Tasks /node
<code>\$\$SLURM_TASKS_PER_NODE</code>	# " " " "
<code>\$\$SLURM_CPUS_PER_TASK</code>	# Αριθμός threads / Task
<code>\$\$SLURM_MEM_PER_NODE</code>	# Μνήμη / node (MB)

## SLURM User/Group resource limits

- Στο SLURM το κάθε account έχει κάποια όρια πόρων που μπορεί να ζητήσει/χρησιμοποιήσει. Τα όρια αυτά εφαρμόζονται σε όλους του χρήστες του account. Αυτά είναι :
  - Αριθμός Jobs που μπορούν να εκτελούνται ταυτόχρονα
  - Αριθμός Jobs που μπορούν να εκτελούνται ή να βρίσκονται σε αναμονή
  - Μέγιστος αριθμός cores ή nodes που μπορούν να χρησιμοποιηθούν ταυτόχρονα από jobs ενός account.
  - Μέγιστη χρονική διάρκεια εκτέλεσης ενός Job
  - Μέγιστος αριθμός nodes που μπορεί να ζητήσει ένα Job
  - Μέγιστος αριθμός cores που μπορεί να ζητήσει ένα Job
  - Συνολικός αριθμός core hours στη διάρκεια ενός project.

- Ο Scheduler στο ARIS είναι FIFO with Backfill και Fairsharing. Αυτό σημαίνει
  - Το job που υποβλήθηκε πρώτο θα εκτελεστεί πρώτο
  - Από τη στιγμή που ξεκινάει η εκτέλεση, η εργασία θα τελειώσει το αργότερο μετά από όσο χρόνο ζητήθηκε στο SLURM script.
  - Εάν το σύστημα έχει μεν ελευθερους πόρους (cores/nodes/memory) αλλά δεν είναι αρκετοί για να τρέξει το πρώτο στη σειρά από τα queued, τα επόμενα jobs θα περιμένουν
  - εκτός...

- Κάποιο από τα επόμενα jobs ζητάει πόρους που υπάρχουν, και ο χρόνος εκτέλεσης που ζητάει είναι μικρότερος από τον πιο κοντινό αναμενόμενο χρόνο τέλους των jobs που εκτελούνται. Αυτό το job θα παρακάμψει τη σειρά, και θα εκτελεστεί πρώτο χωρίς να προκαλέσει καμιά καθυστέρηση σε άλλα jobs.
- Έτσι το σύστημα έχει τη μεγαλύτερη δυνατή χρήση.
- Ζητήστε λίγο παραπάνω από όσο χρόνο υπολογίζετε ότι χρειάζεται η εργασία σας και όχι το μέγιστο που μπορείτε.
- Fairshare
  - Παράγοντες που επηρεάζουν το priority
    - Χρόνος αναμονής
    - Μέγεθος job σε nodes

## Χρήση του ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

- Σχετική χρήση απο groups account π.χ. 80% production, 10% preparatory κλπ.
- Τι θα γίνει αν 4-5 χρήστες στείλουν εκατοντάδες jobs ?
- Το Fairshare αναλαμβάνει να αλλάξει τα priorities ώστε σε επίπεδο εβδομάδας κάποιος/α account να μην μονοπωλεί το σύστημα
- Όσο πιο κοντά στην κατανάλωση του budget βρίσκεται ένα account, τόσο μικραίνει το priority
- Τα jobs που χρειάζονται πολλά nodes

## Εξομοίωση PBS

- Υπάρχει εγκατεστημένη η εξομοίωση του PBS/Torque. Χρήστες που είναι εξοικωμένοι στη χρήση PBS μπορούν να χρησιμοποιήσουν τα PBS scripts και εντολές.
- Η εξομοίωση του PBS καλύπτει μεγάλο βαθμό περιγραφής εργασιών, αλλά όχι όλα

## SLURM

sbatch  
squeue  
scancel

```
#!/bin/sh
#SBATCH --mem-per-cpu=2G
#SBATCH -t 1:00:00
#SBATCH --nodes=1
#SBATCH --ntasks-per-node=20
#SBATCH -A train2016
#SBATCH -p compute
....
```

## PBS

qsub  
qstat  
qdel

```
#!/bin/sh
#PBS -l pvmem=2G
#PBS -l walltime=1:00:00
#PBS -l nodes=1:ppn=20
#PBS -A train2016
#PBS -q compute
....
```

## Accounting

- Δείτε τα jobs σας το τρέχον 24ωρο  
**sacct**
- Δείτε τα jobs σας τον τελευταίο μήνα  
**sacct -S 2015-08-14**
- Δείτε πόσο χρόνο (και ενέργεια σε Wh εφόσον χρησιμοποιείτε srun) έχετε καταναλώσει το τελευταίο εξάμηνο  
**myreport**
- Δείτε πόσο από τον χρόνο που σας έχει δοθεί έχετε χρησιμοποιήσει  
**mybudget**



Χρήση του  
ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

## Διαθέσιμα πακέτα

- Compilers/Debuggers
- MPI Implementations
- Libraries
- Applications
- Debuggers/Profilers
- Graphics
- Εφαρμογές

## Βέλτιστες Πρακτικές

- Τα nodes του ARIS διαθέτουν 20 cores και 64 GB RAM Διαθέσιμα για jobs τα 56 GB. Χρησιμοποιήστε πλήρως τα cores των nodes, δηλ. 20 cores/node.

```
--tasks-per-node=20
```

```
--cpus-per-task=1
```

ή

```
--tasks-per-node=2
```

```
--cpus-per-task=10
```

...

ή άλλους συνδιασμούς tasks/threads με γινόμενο 20.

- Σε περίπτωση που χρειάζεται RAM πάνω από 2.8 GB/core, μπορεί να ζητηθούν λιγότερα cores/node με ταυτόχρονη αύξηση της μνήμης / task, π.χ.

```
--tasks-per-node=18
```

```
--cpus-per-task=1
```

```
--mem-per-task=3.1G
```

Χρήση του  
ARIS

Δρ. Δημήτρης  
Ντελλής

Περιεχόμενα

Σύνδεση στο  
σύστημα

Σύστημα  
αρχείων

Environment  
Modules

Batch System  
SLURM  
Accounting

Διαθέσιμα  
πακέτα

Βέλτιστες  
Πρακτικές

## Βέλτιστες Πρακτικές

- Σε περίπτωση που οι απαιτήσεις μνήμης δεν είναι ίδιες για όλα τα process, χρησιμοποιήστε τη μεταβλητή για συνολική μνήμη / node.

```
--tasks-per-node=20
```

```
--cpus-per-task=1
```

```
--mem=56G
```

## Βέλτιστες Πρακτικές

- Εάν για κάποιον λόγο χρειάζεται αριθμός cores όχι πολλαπλάσιο του 20, συνήθως δυνάμεις του 2 (256, 512, κλπ.)
  - Χρησιμοποιήστε το μικρότερο δυνατό αριθμό nodes.

cores	Nodes	tasks/node	Αχρησιμοποίητα cores
64	4	20	16 σε 1 node
128	7	20	12 σε 1 node
256	13	20	4 σε 1 node
512	26	20	8 σε 1 node

- Σύνθηες λάθος που μεταφέρεται από τη χρήση συστημάτων με 12 ή 16 cores

cores	Nodes	tasks/node	Αχρησιμοποίητα cores
64	4	16	4 cores/node σε 4 nodes = 16
90	6	15	5 cores/node σε 6 nodes = 30
128	8	16	4 cores/node σε 8 nodes = 32
480	40	12	8 cores/node σε 40 nodes = 320
512	32	16	4 cores/node σε 32 nodes = 128

## Βέλτιστες Πρακτικές

- Εάν για κάποιο λόγο πρέπει να χρησιμοποιήσετε `mpirun`, χρησιμοποιήστε το χωρίς τα συνήθη `-np`, `-machinefile` κλπ. Συμβαίνει όταν χρησιμοποιούνται, να μην αλλάζει ταυτόχρονα ο αριθμός των `tasks` στο SLURM και ο αριθμός των `tasks` στο `mpirun -np` π.χ.

```
#SBATCH --nodes=10
```

```
#SBATCH --ntasks=200
```

```
mpirun -np 8
```

**Δεσμεύετε (και χρεώνεστε) για 200 cores ενώ χρησιμοποιείτε μόλις 8.**

## Βέλτιστες Πρακτικές

- Εάν η εφαρμογή σας χρησιμοποιεί OpenMP :
  - Φροντίστε ώστε να δίνετε τα σωστά threads/task στο SLURM.
  - Κοινά λάθη :
    - Δεν θέτουμε τη μεταβλητή `OMP_NUM_THREADS=$SLURM_CPUS_PER_TASK`
    - Για όσο χρόνο το job μας τρέχει μόνο του στο node, μπορεί να χρησιμοποιεί όλα τα cores. Εάν έρθει και άλλο job στο node, τότε το load του node θα ανέβει πάνω από 20 και το performance των jobs εξαρτάται κατά πολύ από τα υπόλοιπα jobs στο node.
    - Με Hybrid MPI/OpenMP εφαρμογές, αν δεν θέσουμε τη μεταβλητή `OMP_NUM_THREADS` και χρησιμοποιούμε π.χ. 20 tasks/node, τότε το load του node γίνεται  $20 \times 20 = 400$ , με αποτέλεσμα ελαττωμένο performance.
    - Στο script template υπάρχει κώδικας που μας προστατεύει από αυτό. Αρκετοί αφαιρούν αυτό το κομμάτι....

## Βέλτιστες Πρακτικές

- Εάν η εφαρμογή σας έχει διαδικασία save/restart χρησιμοποιήστε τη. Αντί για jobs της π.χ. 1 εβδομάδας, προτιμήστε 7 jobs της 1 ημέρας χρησιμοποιώντας τα dependencies του SLURM.
- Βασικό πρόβλημα στα Hexascale συστήματα.
- Στο πρώτο call σε ορισμένους χρήστες δόθηκε η δυνατότητα να τρέχουν jobs των 7 ή 15 ημερών λόγω αδυναμίας save/restart.

Ποσοστό jobs που τελειώσαν κανονικά αρκετά μικρό (διακοπές ρεύματος, υπερθέρμανση, αστοχία υλικού, κλπ.).

## Βέλτιστες Πρακτικές

- Χρησιμοποιήστε το template στο <http://doc.aris.grnet.gr/scripttemplate/> για να φτιάξετε το SLURM script σας. Περιέχει έλεγχο για το αν θέτετε ή όχι τις αντίστοιχες μεταβλητές.
- Επικοινωνήστε με το [support \[at\] hpc.grnet.gr](mailto:support[at]hpc.grnet.gr) για όποιο πρόβλημα ή απορία έχετε.