# Utilização do Ambiente de processamento paralelo do LAD

contato.lad@pucrs.br

suporte.lad@pucrs.br

# Índice:

Introdução 1- Infraestrutura 1.1- Acesso ao LAD 1.2- Pontos de Montagem 1.3- Cópia de Arquivos/Diretórios 3- Quotas 4- Torque 4.1- Comando "gstat" 4.2- Comando "pbsnodes" 4.3- Comando "gdel" 4.4- Comando "qsub" 4.4.1- Parâmetros do "qsub" 4.5- Modo Interativo 4.6- Modo Batchjob 5- Aplicações 5.1- Scripts "-vars.sh" 5.2- Arquivo ".bashrc" 6- Processamento Paralelo e MPI 6.1- Variável "PBS\_NODEFILE" 6.2- Execução de aplicações com MPI 7- Permissões dos Arquivos

# Introdução

O LAD é um laboratório que provê recursos computacionais de alto desempenho para os grupos de pesquisa da PUCRS e pesquisadores externos ligados a esses grupos. Nele, os pesquisadores podem contar com a disposição de um grande conjunto de máquinas e dispositivos de armazenamento para a realização de tarefas com alta demanda computacional.

O LAD presta serviços de alocação de servidores 24x7 e de clusters de processamento paralelo. Por meio deste documento trataremos sobre a infraestrutura e a utilização do ambiente de processamento paralelo do laboratório, servindo como um manual para os usuários. Também abordaremos a utilização do MPI, que é bastante comum neste tipo de ambiente.

# 1 Infraestrutura

No LAD, temos uma máquina responsável pela gerência dos recursos disponíveis nos clusters, a qual é chamada de "Marfim". Podemos dizer que se trata de uma "central de acessos", onde os usuários irão alocar e acessar as máquinas dos clusters. Por esse motivo, na Marfim não deve ser feito nenhum processamento pesado.

Atualmente o LAD possui 5 clusters. Sâo eles: Amazônia, Atlântica, Cerrado, Pantanal e Nimbus. Parte dos equipamentos do LAD são reservados para alocação 24x7, onde os usuários tem acesso administrativo a uma máquina física ou virtual para hospedagem de serviços que devem ficar disponíveis 24 horas por dia. Outra parte é utilizada para processamento em cluster, onde os usuários fazem alocações momentâneas de máquinas com maior capacidade computacional para a execução de aplicações paralelas. Para mais informações sobre cada cluster, acesse:

http://www3.pucrs.br/portal/page/portal/ideia/Capa/LAD/LADInfraestrutura/LA DInfraestruturaHardware

# 1.1 Acesso ao LAD

Na PUCRS temos uma rede chamada "PORTOALEGRE". Essa é a rede comum da universidade, administrada pelo GTIT e onde praticamente todas as estações de trabalho e laboratórios estão conectados. A PUCRS também possui outras redes, porém somente a rede Wi-Fi denominada "PUCRS" faz parte da rede PORTOALEGRE.

A infraestrutura do LAD é uma subrede autônoma da rede PORTOALEGRE, ou seja, a equipe tem autonomia na configuração e administração da subrede, porém está sob as politicas do GTIT para acessos externos ao ambiente do LAD. O acesso ao LAD é permitido para toda a rede PORTOALEGRE. Redes Wi-Fi como "eduroam" e "portal" são consideradas inseguras pelo GTIT e, por isso, não tem acesso ao LAD. Para usuários localizados fora da universidade, o acesso é permitido apenas através de um IP estático da internet. Caso o usuário possua um, o mesmo poderá solicitar ao LAD a liberação para seu IP.

Quando estamos conectados à internet, temos um ponto de acesso que possui um endereço IP visível na internet, esse é o que chamamos aqui de "IP da internet" (ou IP público). Existem muitos sites onde é possível analisar sobre qual IP uma máquina ou uma rede se conecta à internet. Consideramos um IP "estático" da internet quando a máquina ou rede utiliza sempre o mesmo endereço IP para se conectar à internet. Os usuários comuns de internet banda larga costumam utilizar IP's dinamicamente disponibilizados pelas operadoras, ou seja, toda vez que o usuário se autentica na operadora (por exemplo, quando o modem é reiniciado), a operadora provê um endereço IP diferente, inviabilizando a criação de regras para acesso ao LAD. Universidades e grandes empresas possuem contratos especiais com as operadoras, utilizando IP's estáticos que permitem a criação das regras.

Para acessar os serviços do LAD é necessário possuir uma conta. Para solicitar uma conta para um projeto/grupo existente, basta mandar a solicitação (informando o nome completo, e-mail e matricula do requerente) para o e-mail "suporte.lad@lista.pucrs.br" com cópia ao coordenador do grupo, para que o mesmo aprove o cadastro da nova conta. No caso da criação de um novo grupo, a solicitação deve ser feita no sistema do Instituto Idéia através do site:

http://www3.pucrs.br/portal/page/portal/ideia/Capa/

As contas cadastradas são nominais, ou seja, cada usuário possuí uma conta e é responsável pelo que é feito através dela. Por esse motivo, passamos algumas indicações básicas:

- Que as contas/senhas não sejam compartilhadas a terceiros
  - O Senhas anotadas em locais acessíveis por terceiros podem gerar utilização indevida da conta.
  - Utilize uma senha complexa, contendo letras, números e/ou caracteres especiais.
    - O Muitos estudos indicam que as senhas mais seguras são as mais extensas, mesmo que ofereçam um grau menor de complexidade.
  - Não esqueça de alterar a senha no primeiro acesso, pois só então ela será 100% privada.

Após obter uma conta, deve-se efetuar o login no servidor de acesso do LAD através de SSH, conforme exemplo abaixo executado em um terminal Linux:

# ssh <usuário>@marfim.lad.pucrs.br

Atenção: A notação "<>" é usada para variáveis e também será usada em outros exemplos neste documento. No caso acima, quando o comando for executado, "<usuário>" deve ser alterado para o nome de usuário (username) da conta, por exemplo "joao.silva".

Para usuários de máquinas com o Sistema Operacional Windows, existem diversas ferramentas para se fazer o acesso SSH, Por exemplo, o "PuTTY" (<u>http://www.putty.org</u>).

Para mudar a senha, após feito o SSH digite o comando abaixo e siga as instruções que serão apresentadas:

# yppasswd

# 1.2 Pontos de Montagem

O LAD possui alguns diretórios montados a partir de equipamentos de armazenamentos compartilhados na rede. No ambiente de cluster, os diretórios "/usr/local" (onde estão as aplicações) e "/home" (onde estão os diretórios dos usuários) estão, fisicamente, em um destes equipamentos e não nos discos de cada máquina.

Por serem diretórios compartilhados na rede, estes serão idênticos, independente de qual máquina do LAD o usuário estiver. Sendo assim, qualquer modificação feita em seus arquivos ou sub diretórios, na prática serão aplicados no equipamento compartilhado, se refletindo nas demais máquinas. Também, como o acesso é feito através da rede, a leitura e escrita de arquivos podem ser mais lentos quando comparados a um disco local.

# 1.3 Cópia de Arquivos/Diretórios

É possível o usuário realizar cópias de arquivos e diretórios entre a sua máquina local e o LAD, sempre através do protocolo SSH. Caso o Sistema Operacional do usuário seja o Linux, o usuário poderá copiar os arquivos através do comando "SCP". Em máquinas Windows (ou até mesmo Linux), outras ferramentas estão disponíveis para cópia de arquivos por SSH, por exemplo, o "FIleZilla" (<u>https://filezilla-project.org</u>).

O uso do SCP é definido abaixo:

# scp <ArquivoOrigem> <LocalDestino>

Ou no caso de diretórios, para realizar a cópia devemos apenas acrescentar o parâmetro "-r" como abaixo:

# scp -r <DiretórioOrigem> <LocalDestino>

Para copiar arquivos ou diretórios do LAD para a sua máquina local, temos a definição abaixo, notando que o usuário deverá estar realizando o comando localmente da sua máquina, ou seja, não conectado à Marfim.

#### # scp

<usuário>@marfim.lad.pucrs.br:<ArquivoOuDiretórioComCaminhoCompleto><DiretórioLocalDestino>

Por exemplo, o usuário "joao.silva" deseja copiar o arquivo "arquivo.txt" localizado em "/home/joao.silva/testes/" para o seu diretório local "/home/joao/Desktop/":

# scp joao.silva@marfim.lad.pucrs.br:/home/joao.silva/testes/arquivo.txt
/home/joao/Desktop/

Outro exemplo, o usuário "joao.silva" deseja copiar todo o diretório "diretorio\_1" localizado em "/home/joao.silva/testes/" para o seu diretório local "/home/joao/Desktop/":

# scp -r joao.silva@marfim.lad.pucrs.br:/home/joao.silva/testes/diretorio\_1/
/home/joao/Desktop/

Já para copiar um arquivo da sua máquina local para o seu diretório no LAD, temos a definição abaixo, notando que o usuário deverá executar o comando também da sua máquina local.

# scp <ArquivoComCaminhoCompleto>
<usuário>@marfim.lad.pucrs.br:<DiretórioComCaminhoCompleto></use

Por exemplo, o usuário "joao.silva" deseja copiar o arquivo "arquivo.txt" localizado na sua máquina local em "/home/joao/Desktop/" para o seu diretório no LAD "/home/joao.silva/teste/":

# scp /home/joao/Desktop/arquivo.txt
joao.silva@marfim.lad.pucrs.br:/home/joao.silva/testes/

Outro exemplo, o usuário "joao.silva" deseja copiar todo o diretório "diretório\_1" localizado na sua máquina local em "/home/joao/Desktop/" para o seu diretório no LAD "/home/joao.silva/teste/":

# scp -r /home/joao/Desktop/diretorio\_1
joao.silva@marfim.lad.pucrs.br:/home/joao.silva/testes/

# 3 Quotas

O LAD possui um sistema de quota para limitar o uso de armazenamento nos diretórios de usuários (Home). Inicialmente, cada usuário possui uma quota de 10 Gigabytes. A quota pode ser visualizada quando é feito o login na Marfim.



Também é possível analisar a sua quota executando o comando "usoQuotas.sh", como abaixo:

@marfim:~\$ usoQuota.sh Check quota disk for your user: Total: 10240 MB Used: 3087.38 MB Havendo necessidade de um espaço de armazenamento maior, o usuário pode contactar o suporte para conversar sobre uma possível mudança ou a utilização de um novo ponto de montagem (com tamanho limitado) para uso livre do grupo (sem distinção por usuário).

# 4 Torque

No nosso servidor de acesso (Marfim) temos o gerenciador de recursos chamado Torque, o qual é responsável pela gerência de alocações das máquinas dos clusters. Para a utilização do ambiente LAD, o Torque provê alguns comandos:

Programs to use the cluster: Torque: qsub qdel qstat pbsnodes qnodes

# 4.1 Comando "qstat"

Comando usado para verificar os estados atuais das máquinas e dos Jobs\* que estão sendo executados. Ao executar o comando, haverão as informações como na imagem abaixo para cada cluster, obviamente com algumas mudanças, pois são clusters distintos com recursos e alocações diferentes.

\*Job é uma sequência de processos que o usuário deseja executar em uma ou mais máquinas.

***************************************								
Cluster: cerrado	o - O Node	s Free / 2	9 Exclusive	/ 0 Shared	1 / 2 S	eparated		
cerrado01n: exc	clusive	cerrado0	2n: exclusi	ve ceri	rado03n	: exclusive		
cerrado04n: exc	clusive	cerrado0	5n: exclusi	ve ceri	rado06n	: exclusive		
cerrado07n: exc	lusive	cerrado0	8n: exclusi	ve ceri	rado09n	: exclusive		
cerrado10n: exc	lusive	cerrado1	1n: exclusi	ve ceri	rado12n	: exclusive		
cerrado13n: exc	lusive	cerrado1	4n: exclusi	ve ceri	rado15n	: exclusive		
cerrado17: exc	lusive	cerrado	18: exclusi	ve cer	rrado19	: exclusive		
cerrado20: exc	lusive	cerrado	21: exclusi	ve cer	rrado22	: exclusive		
cerrado23: exc	lusive	cerrado	24: exclusi	ve cer	rrado25	: exclusive		
cerrado26: exc	lusive	cerrado	27: exclusi	ve cer	rrado28	: exclusive		
cerrado29: exc	lusive	cerrado	30: exclusi	ve cer	rrado31	: separated		
cerrado32: sep	parated							
*****	*********	*********	*******	*******	*######	*****		
Jobs running		-		-1				
Job Id Username	Group	Job name	Reserved	Elapsed	Cores	Started at		
cocoo bassissa	Andop	CTDTN	50.00.00		00	10/6 15.01.14		
68630 Kasslano.	AcadDR	STDIN	50:00:00	-	00X24	19/6 15:21:14		
68636 Kasslano.	ACadUR	SIDIN	50:00:00	00:00:01	00X24	19/6 17:13:34		
69158 ezequiel.	plumes	Batchjob	300:00:00	73:04:51	16X24	6/7 13:00:35		
69169 ratael.be	Lad	cerrado2/	300:00:00	50:52:00	00x24	7/7 11:14:24		
69180 leandro.g	NanoFis E	SatchjobR4	300:00:00	11:15:25	06x24	9/7 02:50:03		
69188 nathan.li	NanoFis B	Batchjobfe	300:00:00	01:03:32	06x24	9/7 13:02:38		
None queued jobs								

No exemplo acima temos o cluster cerrado, onde podemos analisar 2 tipos de dados. São eles:

- **1. Estado do Cluster e das máquinas**, os quais possuem as seguintes informações:
  - a. cerrado: nome do cluster.
  - b. cerradoXX: nome da máquina.
  - c. free: máquina com todos os processadores livres.
  - d. **exclusive**: máquina com todos os processadores alocados por um ou mais usuários.
  - e. **separeted**: máquina com alocação momentânea usando um ambiente diferente, onde é retirada do cluster para casos específicos.
  - f. **shared**: máquina com apenas alguns processadores alocados, possibilitando outros usuários à usarem os processadores livres.
- 2. Estado dos Jobs e filas, os quais possuem as seguintes informações:
  - a. Jobs running: atuais Jobs sendo executados no cluster.
  - b. **Queued jobs**: Jobs aguardando a liberação de recursos necessários para a execução.

- c. **Job Id**: número de identificação do Job.
- d. Username: usuário que submeteu o Job.
- e. Group: grupo do usuário.
- f. Job name: nome do Job. Pode ser especificado no comando de alocação ou é obtido a partir do nome do arquivo Batchjob (falaremos mais sobre formas de alocação nos próximos capítulos).
- g. **Reserved**: tempo reservado para o Job, ou seja, o tempo máximo que o Job poderá executar, podendo ser finalizado ou cancelado antes desse período (falaremos mais sobre os motivos para o termino antecipado nos próximos capítulos).
- h. Elapsed: tempo que o Job está executando.
- i. Cores: número de máquinas "X" número de processadores cada. ex.: 02x16 = 2 máquinas alocadas com 16 processadores cada uma. Caso o número de máquinas seja "00", quer dizer que o usuário especificou manualmente qual(ais) máquina(s) deseja alocar.
- j. Started at: data e horário que o Job começou a ser executado.

### 4.2 Comando "pbsnodes"

Comando usado para verificar os estados de cada máquina (individualmente) de forma mais detalhada.

Ex.: máquina "cerrado27"

errado27
<pre>state = job-exclusive</pre>
np = 24
properties = cluster-Cerrado
ntype = cluster
jobs = 0/69169.marfim.lad.pucrs.br, 1/69169.marfim.lad.pucrs.br, 2/69169.marfim.lad.pucrs.br, 3/69169.marfim.lad.pucrs.br, 4/69169.marfim.lad.pucr
br, 5/69169.marfim.lad.pucrs.br, 6/69169.marfim.lad.pucrs.br, 7/69169.marfim.lad.pucrs.br, 8/69169.marfim.lad.pucrs.br, 9/69169.marfim.lad.pucrs.br,
/69169.marfim.lad.pucrs.br, 11/69169.marfim.lad.pucrs.br, 12/69169.marfim.lad.pucrs.br, 13/69169.marfim.lad.pucrs.br, 14/69169.marfim.lad.pucrs.br, 1
69169.marfim.lad.pucrs.br, 16/69169.marfim.lad.pucrs.br, 17/69169.marfim.lad.pucrs.br, 18/69169.marfim.lad.pucrs.br, 19/69169.marfim.lad.pucrs.br, 20
9169.marfim.lad.pucrs.br, 21/69169.marfim.lad.pucrs.br, 22/69169.marfim.lad.pucrs.br, 23/69169.marfim.lad.pucrs.br
status = rectime=1436461942, varattr=, jobs=69169.marfim.lad.pucrs.br, state=free, netload=59837039,gres=, loadave=0.08, ncpus=24, physmem=24677460kb, ava
.mem=72634176kb,totmem=73505872kb,idletime=181807,nusers=2,nsessions=2,sessions=1749 2298,uname=Linux cerrado27 3.2.0-23-generic #36-Ubuntu SMP Tue Ap
10 20:39:51 UTC 2012 x86_64,opsys=linux

No exemplo acima temos "cerrado27", onde podemos analisar os seguintes dados:

state: estado atual da máquina.
np: número de processadores da máquina.
properties: contém o nome do cluster da máquina.
jobs: contém o número de cada processador e qual Job o alocou. ex.:
10/1234.marfim.lad.pucrs = processador número 10 está sendo utilizado pelo
Job id "1234".

**status**: informações adicionais da máquina, como tempo de atividade, memória RAM (physmem), etc.

# 4.3 Comando "qdel"

Comando usado para remover algum Job criado, em execução ou na fila (aguardando liberação dos recursos). Somente usuários administradores do LAD possuem a permissão de remover Jobs de outros usuários, os demais podem remover apenas seus próprios Jobs. O uso dele é bastante simples:

# qdel <job id>
exemplo: qdel 1234

# 4.4 Comando "qsub"

Comando usado para submeter um Job, podendo ser no modo interativo ou no modo Batchjob. Relembrando que Job se trata de uma série de processos que o usuário deseja executar em uma ou mais máquinas.

# 4.4.1 Parâmetros do "qsub"

O comando possui muitos parâmetros, todos podem ser consultados com detalhes utilizando o comando "man". O man é um comando de manual, que é utilizado para orientar os usuários na utilização de comandos do Linux, descrevendo funções do comandos e seus parâmetros. Para manual do "qsub", execute o comando:

# man qsub

Os principais parâmetros serão detalhados abaixo:

-I = Alocação no modo interativo.

 -V = Modo Verbose, mostra algumas informações adicionais do sistema Torque.

-M <email do usuário> = Define o e-mail para alerta de iniciação e finalização do job.

-d <diretório de trabalho> = Define o diretório no qual a alocação será direcionada. Caso esse parâmetro não seja especificado, o padrão é "/home/<usuário>/". Caso seja alocação Batchjob, será nessa pasta que será criado o arquivo com as saídas do Job (outputs dos comandos executados).

-I = Parâmetro mais importante. É a definição dos recursos de que o usuário deseja alocar. Há políticas de limitação (definidas pela equipe de suporte) feitas no Torque, por isso, a alocação pode ser recusada (o comando exibe um alerta de que o ambiente não oferece os recursos solicitados). Caso o usuário

deseje mais recursos do que é permitido nas politicas, o mesmo deve entrar em contato com o suporte para avaliação da necessidade.

 É importante salientar que as definições deste parâmetro se tratam apenas dos recursos reservados, e não os que serão consumidos pela aplicação. Portanto, os comandos de execução da aplicação (podem variar para cada uma) definem como os recursos reservados serão utilizados.

[nodes=<número de máquinas> | <nome da máquina>] [:ppn=<nº de processadores por máquina>] [:cluster-<nome do cluster>,walltime=<tempo a ser reservado>]

exemplo1: -I nodes=2:ppn=16:cluster-Atlantica,walltime=05:00:00

No exemplo acima, o usuário define que pretende alocar 2 máquinas do cluster Atlantica com 16 processadores cada, por um período máximo de 5 horas. Em "nodes" é possível especificar qual máquina deseja alocar, ex.: "nodes=atlantica01", e para especificar mais de uma máquina, use o exemplo abaixo.

[nodes=<nome da máquina>:ppn=<ppn>+<nome da máquina>:ppn=<ppn>+...] [:cluster-<nome do cluster>,walltime=<tempo a ser reservado>]

#### exemplo2: -I

nodes=atlantica01:ppn=16+atlantica05:ppn=16+atlantica10:ppn=16:cluster-Atlantica,walltim e=05:00:00

No exemplo acima, o usuário define que pretende alocar as máquinas "atlantica01", "atlantica05" e "atlantica10", todas com 16 processadores cada, por um tempo máximo de 5 horas.

#### 4.5 Modo Interativo

É iniciada uma sessão para o usuário em uma das máquinas alocadas, onde o usuário é transferido da sua sessão atual (marfim) para essa sessão criada, como se o usuário tivesse se conectado à maquina alocada por SSH. O Job fica vinculado à essa nova sessão. Caso o usuário saia da mesma (comando "exit", por exemplo) ou a conexão seja interrompida (considerando toda a conexão, desde a máquina local do usuário, até a máquina final), o Job também é encerrado.

```
@marfim:~/exemplos/torque$ cd
@marfim:~$ qsub -V -I -l nodes=2:ppn=16:cluster-Atlantica,walltime=05:00:00
qsub: waiting for job 69195.marfim.lad.pucrs.br to start
qsub: job 69195.marfim.lad.pucrs.br ready
Running PBS prologue script
Checking all prerequisites...
Done.
@atlantica09:~/
```

No exemplo acima, o usuário alocou 2 máquinas do cluster Atlantica e sua sessão foi transferida para a máquina atlantica09. Nesse caso o usuário

alocou duas máquinas, com isso o acesso à essas máquinas está liberado para ele, podendo se conectar à qualquer uma através de "ssh".

Atenção: Uma sessão ssh comum não é igual a sessão iniciada pelo Torque (através da alocação), pois as variáveis de ambiente criadas na alocação podem vir a ser utilizadas pela aplicação. Assim, é indicado que as aplicações sejam executadas através da sessão de alocação (na mesma máquina, inclusive). Caso o usuário queira fazer outras conexões com a(s) maquina(s), é aconselhado que novas sessões sejam abertas por ssh (como em um novo terminal).

# 4.6 Modo Batchjob

O usuário submete seus comandos em um script para ser executado em uma das máquinas alocadas. Quando acabar a execução do script, o job é finalizado e o usuário poderá ver as saídas (retornos) dos comandos executados em um arquivo ".o" (gerado no diretório especificado no parâmetro "-d" do comando qsub).

Um exemplo de Batchjob está localizado em "/home/<usuário>/exemplos/torque/Batchjob".

Lembrando que o "walltime" é exatamente como no modo Interativo, se trata do número máximo de horas alocadas, não quer dizer que ficará executando todo esse tempo. Caso ultrapasse o tempo de walltime, a execução será interrompida e o Job encerrado. Podemos analisar o arquivo de exemplo na imagem abaixo:

```
#!/bin/bash
##################### are comments
#PBS -m abe
################ Verbose mode
#PBS -V
###################
################ Change these parameters according to your requisites
#PBS -l nodes=1:ppn=16:cluster-Atlantica,walltime=05:00:00
################ Where:
################ ppn = number of cores per node
##################### walltime = max allocation time
################ Please, change this e-mail address to yours
#PBS -M user.name@acad.pucrs.br
###################
#PBS -r n
################ Output options
#PBS -j oe
################ Please, change this directory to your working dir.
#PBS -d /home/user.name/exemplos/torque/
####################
echo Running on host `hostname
echo
echo Initial Time is `date
echo
echo Directory is `pwd
echo
echo This jobs runs on the following nodes:
echo `cat
                   | uniq
echo
echo JOB_ID:
echo `echo
```

############## Command example, if using MPI

###################

echo Final Time is 'date

#./program
sleep 10

#mpirun -machinefile nodefile -np 16 program\_mpi

############# If running a sequential or openMP program

No modo Batchjob, todas as linhas que se iniciam com "#PBS" são comentários que serão interpretados como parâmetros do comando "qsub" (já vistos anteriormente), ou seja, o usuário deve especificar os parâmetros do "qsub" no próprio script. As linhas que não iniciem especificamente com "#PBS" serão interpretadas normalmente como qualquer script bash (como comandos ou comentários). Por exemplo, linhas iniciadas em "##PBS" não serão interpretadas pelo qsub e linhas iniciadas em "PBS" serão interpretadas como um comando, PBS, que não existe.

Os comandos desejados pelo usuário devem ser inseridos após todos os parâmetros do "qsub". O próprio arquivo de exemplo contém informações sobre os parâmetros e locais para a inserção dos comandos desejados para a execução ("Command example..." e "If Running a sequential...").

Para submeter o Job no modo Batchjob, apenas execute o comando "qsub" seguido do caminho relativo do script.

@marfim:~/exemplos/torque\$ qsub Batchjob 69193.marfim.lad.pucrs.br @marfim:~/exemplos/torque\$

No exemplo acima temos um exemplo de submissão do script de exemplo citado anteriormente (como o arquivo está no mesmo diretório do usuário, não é necessário passar o caminho completo). O Job vai para a fila e é iniciado, executado e finalizado sem intervenções do usuário, ou seja, o usuário não precisa se manter conectado ao LAD para a execução. Ao finalizar o Job, teremos o arquivo com as saídas dos comandos executados no diretório especificado no parâmetro "-d". Caso o parâmetro não seja especificado, será criado no home do usuário "/home/<usuário>/". Na figura abaixo, o diretório definido foi "/home/<usuário>/exemplos/torque/". O nome do arquivo com os resultados sempre será "NomeDoJob"+".o"+"JobId" e o usuário terá total acesso à ele.

> @marfim:~/exemplos/torque\$ ls Batchjob Batchjob.o69193 program program\_mpi program\_mpi.c

# **5** Aplicações

Na imagem abaixo, podemos ver algumas das aplicações que estão disponivéis em "/usr/local/".

Qmar	fim:/usr/local\$ ls	
ABCtoolbox	MPI-blastn	boost
ATLAS	MPIBlast	boost_intel
Amber	Matlab	cesm
Amber9	MrBayes-3.1.2	charm
BCFTools	NCBI-taxcollector	conteiners
Best-2.3.1	NPB	cpu-benchmark
Blast2.2	NVIDIA_GPU_Computing_SDK	crono
Bowtie	NVIDIA_GPU_Computing_SDK.bak	cuda
CLHEP	Orca-2.9.1	cuda-7.0
COPEread	PAPI	cufflinks-2.0.0
Cilk	PSMC	cufflinks-2.0.0_intel
Cilk.old	Pangea+	cutadapt-1.7.1
FFTW	ParaView-3.14.1-Linux-64bit	cutadapt-1.8.1
FFTW2	ParaView-3.14.1-Linux-64bit.tar.gz	cutadapt-1.8.1-copy
FastFlow	ParaView_3.8.1	cxsc-2-5-0

As aplicações localizadas nesse diretório são instaladas pelos administradores do LAD. O usuário pode instalar aplicações que deseje no seu diretório "/home/<usuário>", sendo possível também solicitar a instalação de alguma aplicação no "/usr/local", contatando o suporte do LAD por email.

### 5.1 Scripts "-vars.sh"

As aplicações estão localizadas em uma unidade de armazenamento acessível para todas as máquinas dos clusters, no diretório "/usr/local/". Para a utilização das aplicações, temos os scripts "<aplicação>-vars.sh", os quais estão localizados dentro do diretório de cada aplicação. Caso a aplicação possua mais de uma versão, existirá um script para cada versão da mesma e um script sem versão definida, que será apenas um link para a versão mais recente.

Esses scripts são responsáveis por preparar todo o ambiente para a utilização da aplicação. O mais comum é a definição de variáveis de ambiente (variáveis da sessão do usuário). Na inicialização da sessão, diversas variáveis já são criadas para o uso do próprio sistema, e entre elas existe uma lista de diretórios chamada "PATH". O PATH contém os diretórios com os binários (comandos do linux) para executarmos sem precisar digitar todo o caminho do arquivo e sim apenas o "comando" em si.

Quando apenas executamos os scripts "-vars.sh" (Ex: "./script-vars.sh"), as variáveis definidas por ele serão desfeitas após a sua execução, ou seja, as variáveis serão "válidas" somente para a execução do próprio script, não se aplicando a sessão como um todo. Para que as variáveis ali definidas sejam aplicadas na sessão do usuário, devemos executar os scripts através do comando "source" (source script-vars.sh). O comando "source" irá aplicar à sessão atual todas alterações nas variáveis de ambiente feitas pelo script, e não apenas durante a execução do mesmo.

Como citado anteriormente, o mais comum destes scripts é a definição de variáveis de ambiente. Com o comando "export" podemos visualizar todas as variáveis que já estão definidas no sistema, como é mostrado na imagem abaixo:



Como exemplo, podemos ver o script "-vars.sh" da aplicação "Lammps", que é simples e não aplica muitas configurações. Esse adiciona à variável "PATH", um caminho para o diretório que contém os binários da aplicação.



Ao executarmos o script com o comando "source", poderemos ver a alteração feita na variável de ambiente "PATH":

@marfim:/usr/local/Lammps\$ source lammps-vars.sh



### 5.2 Arquivo ".bashrc"

No diretório "home" do usuário (/home/<usuário>/) temos um arquivo chamado ".bashrc", o qual é automaticamente executado quando uma sessão do usuário é iniciada. Caso o usuário sempre utilize uma mesma aplicação (por exemplo, "LAST"), não é necessário sempre estar executando "source /usr/local/LAST/last-vars.sh", apenas é necessário a inserção desse comando ao final do arquivo ".bashrc". Desta forma, sempre que o usuário fizer o login, o comando é executado. Não aconselhamos usar esse método, pois podem haver conflitos entre bibliotecas de diferentes aplicações que um mesmo usuário execute.

O modo aconselhado é, sempre que for utilizar uma aplicação, antes executar "source" para o arquivo "-vars.sh" da mesma, evitando que bibliotecas de outras aplicações possam gerar conflitos. No caso do batchjob, o comando pode ser inserido antes da(s) linha(s) com o(s) comando(s) de execução. Assim, caso o usuário queira usar uma outra aplicação e desfazer as definições de variáveis feitas, somente deverá encerrar a sessão atual e iniciar outra, pois as variáveis modificadas terão efeito somente na sessão atual do usuário.

# 6 Processamento Paralelo e MPI

O processamento paralelo se trata de uma forma de processamento onde são usados múltiplos processadores para resolver um mesmo problema, visando um menor tempo de execução. Por padrão, a grande maioria das aplicações não são paralelas, ou seja, apenas um processo é criado e, consequentemente, apenas um processador (core/núcleo) irá executar o processo. Para que uma aplicação execute de forma paralela, é necessário que:

- 1. Seu código tenha sido preparado para isso, ou seja, os desenvolvedores já a tenham a programado para executar paralelamente.
- 2. Tenha sido compilada e instalada com as bibliotecas necessárias para tal.
  - a. Dependendo das bibliotecas utilizadas, pode ser que a aplicação precise ser executada através de algum sistema "extra" (como o mpirun), que crie o ambiente para execução.

Existem várias formas de programar para que a aplicação execute em paralelo. Uma delas é através do MPI (Message Passing Interface), o qual o uso é muito comum entre os usuários do LAD. O MPI é um padrão para comunicação de dados entre processos, ou seja, permite que diferentes processos troquem mensagens entre si.

Existem diversas implementações deste padrão, como OpenMPI, IntelMPI, MPICH e outros. A utilizada como padrão do LAD é a OpenMPI, mas outras estão instaladas no "/usr/local" e o usuário pode utilizá-las. É importante frisar que o usuário só utilizará alguma outra implementação do MPI se ele mesmo compilar a aplicação (desenvolvida por ele ou a partir de seu código fonte aberto), pois a aplicação precisa ser executada pela mesma implementação do MPI que foi utilizada em sua compilação. Para aplicações instaladas no "/usr/local", o usuário não precisa se preocupar com a implementação utilizada, pois a mesma será configurada no script "-vars.sh" da aplicação.

Estas implementações do MPI envolvem um conjunto de de ferramentas e comandos para compilação e execução da aplicação. No momento da execução, ela cria os diversos processos em um ambiente para a troca de mensagens que pode estar espalhado em diferentes máquinas. Esse ambiente utiliza diversas bibliotecas capazes de utilizar e otimizar o uso de diferentes ambientes de rede.

#### 6.1 Variável "PBS\_NODEFILE"

Sempre que o usuário faz alguma alocação, uma variável de ambiente é criada. Essa variável denomina-se "PBS\_NODEFILE" e nela contém o caminho para um "machinefile" próprio da alocação feita, comumente utilizada em aplicações MPI que veremos a seguir. Esse "machinefile" contém o nome de cada máquina, tantas vezes quanto o número de processadores alocados por cada.

Ao executarmos o comando "export", após feita uma alocação, podemos notar a variável e o caminho que ela possui, como na figura abaixo:

#### declare -x PBS\_NODEFILE="/var/spool/torque/aux//69195.marfim.lad.pucrs.br"

Podemos também executar o comando "cat" juntamente com "\$PBS\_NODEFILE" para exibir o conteúdo do arquivo que a variável define.

Seguindo esse raciocínio, no exemplo abaixo podemos perceber que alocamos duas máquinas com três processadores cada, pois o nome de cada máquina é repetido três vezes.

	<pre>@atlantica03:~\$</pre>	cat	<pre>\$PBS_NODEFILE</pre>
atlantica03			
atlantica03			
atlantica03			
atlantica01			
atlantica01			
atlantica01		3	

#### 6.2 Execução de aplicações com MPI

Para que uma implementação do MPI possa fazer a criação dos processos nas diferentes máquinas, é utilizado um "machinefile" como o contido na variável "PBS\_NODEFILE". No próprio arquivo de exemplo de Batchjob possui um exemplo de execução MPI. Um outro exemplo é o que segue:

#### mpirun -machinefile \$PBS\_NODEFILE -np 32 program\_mpi

Para o exemplo acima, alocamos duas máquinas com 16 processadores cada. Então definimos a variável "PBS\_NODEFILE" como o machinefile e 32 como o número de processos que o MPI irá criar para a execução do nosso programa "program\_mpi". O mpirun percorrerá o arquivo machinefile criando um processo em cada maquina nele referenciado até chegar ao número de processos definidos no parâmetro "np". Se o arquivo machinefile não for declarado, todos os processos serão disparados na máquina atual. Se o machinefile tiver um número menor de referências do que o número de processos declarados no "np", o mpirun percorrerá as referências do arquivo de forma recursiva.

Porém os usuários devem ter em mente que as máquinas do LAD não possuem fisicamente todos os processadores especificados, a maioria das máquinas possuem 2 processadores físicos com X núcleos cada, todas com Hyper-threading.

Hyper-threading é uma tecnologia da Intel que torna cada núcleo físico capaz de executar 2 processos a cada ciclo de clock, assim, o sistema operacional identifica 2 núcleos "virtuais" de processamento para cada núcleo físico. Por exemplo: Em uma máquina com 2 processadores (cada um com 2 núcleos de processamento). Sem Hyper-threading, ao executarmos o comando "htop" veremos 4 núcleos. Porém, caso os processadores tenham a tecnologia da Intel, veremos 8 núcleos (virtuais). O uso do Hyper-threading não significa que cada core tenha o dobro de desempenho, simplesmente contém algumas contém algumas features que, na maioria das vezes, trazem ganhos no tempo total de processamento. Em algumas aplicações o desempenho pode até piorar quando utilizado todos os núcleos virtuais. Por esse motivo, o indicado é que o usuário faça simulações iguais, mas com diferentes números de processos por máquina. Por exemplo, se uma máquina tem 16 núcleos virtuais (8 físicos), o usuário pode testar a execução de 8 processos por máquina.

Para testar com diferentes números de processos, o usuário poderá criar o seu próprio "machinefile" a partir do "PBS\_NODEFILE". Isso é fundamental, pois se o usuário apenas alterar o parâmetro "-np" do MPI, os processos poderão não se espalhar adequadamente entre as máquinas alocadas. Por exemplo, se o usuário reservou 2 máquinas com 16 processadores cada e deseja usar 8 processadores de cada maquina, não adianta apenas mudar o parâmetro "-np" de 32 para 16, pois no "PBS\_NODEFILE" as 16 primeiras linhas correspondem a uma única máquina. Desta forma, 16 processos rodariam em uma das máquinas enquanto a outra não executará nenhum. Para resolver esse problema, podemos criar um arquivo, denominado "nodefile" (por exemplo), e remover as referências duplicadas, usando o exemplo abaixo:

cat \$PBS\_NODEFILE | uniq > nodefile

Com esse comando, criamos o arquivo "nodefile" com apenas uma referencia de cada máquina alocada. Lembrando que esse comando também pode ser inserido no script BatchJob.

@atlantica09:~/exemplos/torque\$ cat \$PBS\_NODEFILE | uniq atlantica09 atlantica03

Assim, podemos especificar quantos processos desejarmos, pois ao chegar ao final do arquivo (em "atlantica03") e ter mais processos para executar, o MPI irá voltar para o inicio do arquivo (em "atlantica09"). Ou seja, os processos serão divididos igualmente entre as máquinas (dependendo do número de processos escolhido e o número de máquinas). Agora só precisamos executar o "mpirun" utilizando o novo arquivo machinefile.

#### mpirun -machinefile nodefile -np 16 program\_mpi

Para fins de teste e acompanhamento da execução, é possível acessar as máquinas alocadas por ssh (máquinas não alocadas não permitem acesso) para visualizar os processos em execução e a utilização dos processadores. Um comando que pode ser usado para tal visualização é o "htop", para isso basta o usuário acessar a(s) máquina(s) alocada(s) e executar o comando.

# 7 Permissões dos Arquivos

Todos os arquivos no Linux possuem 3 tipos de permissões associadas a 3 tipos de usuários.

As permissões são de:

- leitura, representada pela letra "r" (read);
- escrita, representada pela letra "w" (write);
- execução, representada pela letra "x" (execute).

Os tipos são:

- O proprietário (usuário) do arquivo;
- Os usuários de um determinado grupo (por padrão, é o mesmo grupo do usuário);
- Outros usuários.

Podemos verificar as permissões dos arquivos através do comando "ls", com o uso dos parâmetros "l" e "a" ("-la").

@marfim:/usr/local/LAST\$ ls -la								
total 20								
drwxr-xr-x	4	root	root	4096	Jan	6	2015	
drwxr-xr-x	165	root	root	4096	Jul	17	18:26	
drwxr-xr-x	3	root	root	4096	Jan	6	2015	last-529
drwxr-xr-x	3	root	root	4096	Jan	6	2015	last-529-UB10.04
- FW-FF	1	root	root	377	Mar	18	17:42	last-529-vars.sh
lrwxrwxrwx	1	root	root	16	Jan	б	2015	<pre>last-vars.sh -&gt; last-529-vars.sh</pre>

Esse comando listará todos os objetos do local atual, mas permite especificar outro local após o parâmetro "-la". Essa lista conterá informações sobre o tipo do objeto, permissões, proprietário (usuário) e grupo.

Na imagem acima, a primeira letra de cada arquivo é o tipo de objeto, exemplo: "d" é diretório e "l" é um link simbólico a outro arquivo. Após a primeira letra vêm as permissões do arquivo, com as 3 sequências de 3 letras. Também apresenta o proprietário, o "root" (nesse caso), e o grupo, que também se chama "root".

A primeira sequência são as permissões do proprietário do arquivo, a segunda sequência é dos usuários do "grupo dono" do arquivo (não necessariamente é o grupo ao qual o proprietário pertence) e a terceira sequência são as permissões para os outros usuários.



Para fazer alguma alteração nas permissões de um certo arquivo ou diretório, temos o comando "chmod". O uso dele é bastante simples:

- # chmod <permissão> <arquivo/diretório>
- # chmod -R <permissão> <diretório>

O parâmetro "-R" quer dizer recursivo, ou seja, aplicará a alteração da permissão recursivamente para todos os objetos localizados dentro do diretório. Caso o usuário mude a permissão de um diretório sem o parâmetro de recursividade, as permissões afetarão apenas o diretório e não seu conteúdo interno.

A variável "permissão" pode ser definida de várias formas, para esse texto, explicaremos a definição com 3 números, para a permissão do usuário, grupo e outros, respectivamente. O número para cada um é obtido a partir do valor em decimal do binário formado pela sequência de 0 (permissão não concedida) e 1 (permissão concedida) para cada tipo de permissão. Caso no lugar da letra tenha um sinal "-" significa que o objeto não possui aquela permissão.

Permissão	Binário	Decimal
	000	0
x	001	1
-w-	010	2
-wx	011	3
r	100	4
r-x	101	5
rw-	110	6
rwx	111	7

### **Exemplos**

# chmod 775 arquivo.pl

No caso acima, no arquivo "arquivo.pl", estamos atribuindo todas as permissões (leitura, escrita e de execução) para o proprietário e para o grupo. Para os outros usuários, atribuindo somente as permissões de leitura e execução.

# chmod 777 arquivo.pl

No caso anterior, estamos atribuindo total acesso (leitura, escrita e execução) ao arquivo para todos os tipos de usuários.

# chmod -R 750 pasta

No exemplo acima, estamos atribuindo ao diretório "pasta" e recursivamente para todo o conteúdo nele contido, as 3 permissões para o proprietário, somente leitura e execução para o grupo proprietário e nenhuma permissão para os outros usuários.