

# Técnica de Caracterização de Cargas de Trabalho de Supercomputadores para Predição do Comportamento de Tarefas Paralelas

Lesandro Ponciano dos Santos<sup>1</sup>, João Paulo D. Silva<sup>1</sup>, Luís Fabrício W. Góes<sup>1</sup>

<sup>1</sup>Instituto de Informática – Pontifícia Universidade Católica de Minas Gerais (PUC Minas)  
Av. Dom José Gaspar, 500 Coração Eucarístico Belo Horizonte - MG - CEP 30535-901

lesandrop@lisd.ufcg.edu.br, {jpds, lfwgoes}@pucminas.br

**Abstract.** *In this work, we propose, implement and analyze a workload characterization technique based on supercomputer log for prediction of parallel jobs behavior, in order to subsidize the reconfiguration of RGSA reconfigurable scheduler. In a case study, we have characterized logs of real supercomputer and have obtained workload's synthetics model. In some logs, we have obtained results with mean similarity of until 85%, comparing the jobs model characterized with historic data, and the jobs data executed after the characterization period. The results are satisfactory if we consider that variations in workloads usually happen.*

**Resumo.** *Neste trabalho, propomos, implementamos e analisamos uma técnica de caracterização para predição de comportamentos de tarefas paralelas, baseada em rastro de supercomputadores, com o propósito de subsidiar a reconfiguração do escalonador reconfigurável de tarefas RGSA. Em um estudo de caso, obtivemos modelos sintéticos de cargas de trabalho através da caracterização de rastros de supercomputadores reais. Dentre os resultados alcançados obtivemos, em alguns rastros, semelhança média de até 85% entre o modelo de tarefas caracterizado com dados históricos e dados de tarefas executadas em período posterior ao caracterizado. Os resultados são satisfatórios considerando-se que, normalmente, ocorrem variações nas cargas de trabalho.*

## 1. Introdução

Nas arquiteturas paralelas e distribuídas, têm-se proposto formas de melhorar o desempenho de seus diversos componentes, tais como, processadores, memórias, redes de comunicação, protocolos de rede etc. Desses componentes destacamos o escalonador de tarefas, responsável por alocar as tarefas nos núcleos de processamento disponíveis. Quando o escalonador utiliza informações sobre a carga de trabalho para realizar o

escalonamento ele é dito com informação [Góes e Martins 2004] [Senger e Santana 2004] senão é dito sem informação [Cirne et al 2007].

Um escalonador com informação, que visa melhorar o desempenho de arquiteturas paralelas, é o Algoritmo Reconfigurável de Escalonamento de Gangues (RGSA) [Góes e Martins 2004]. A partir de um conjunto de políticas de escalonamento pré-programadas, o RGSA se reconfigura sob demanda, selecionando e utilizando as melhores políticas de escalonamento para cada comportamento da carga de trabalho. Para definir as melhores políticas, o RGSA utiliza dados do tempo de submissão, tempo de execução e número de processos. Esses dados são obtidos em históricos de tarefas executadas no sistema.

O RGSA necessita, portanto, de informações sobre o comportamento da carga de trabalho para realizar a reconfiguração. A carga de trabalho expressa o conjunto de tarefas executadas em uma arquitetura paralela, que geralmente são armazenadas em rastros (histórico das tarefas). Os rastros são, geralmente, grandes bases de dados que armazenam diversas informações sobre as tarefas, em testes práticos é necessário gerar um modelo sintético que represente as principais características da carga de trabalho. Uma das formas de gerar esse modelo é a caracterização.

Por meio da caracterização, podem-se sintetizar grandes quantidades de dados em um modelo simplificado que preserva as principais características dos dados que foram utilizados para gerá-lo [Jain 1991]. O processo utilizado para caracterizar a carga de trabalho é definido como técnica de caracterização [Elnaffar e Martin 2006]. Nesse processo podem-se gerar distribuições de probabilidades que descrevem o comportamento da carga de trabalho. No entanto, essas técnicas são mais utilizadas na modelagem do que na predição de comportamentos, por esse motivo decidiu-se gerar modelos de predição de tarefas estruturados no formato de informação requerida pelo escalonador RGSA.

As técnicas de caracterização são definidas principalmente pelos dados utilizados e pelo modelo requerido [Elnaffar e Martin 2006], entretanto, existem etapas comuns à maioria das técnicas de caracterização: *(i)* definição do ponto de referência ao qual a carga será analisada; *(ii)* escolha dos parâmetros que preservem as características mais relevantes para a finalidade do estudo; *(iii)* obtenção dos dados brutos; *(iv)* geração de um modelo da carga de trabalho; *(v)* verificação do modelo gerado.

O problema tratado por este trabalho é a definição de uma técnica de caracterização para predição, modelagem e estruturação de modelos sintéticos, de cargas de trabalho de máquinas paralelas, para subsidiar a adaptação do escalonador RGSA à carga de trabalho. O principal objetivo é propor, implementar, verificar e validar uma técnica de caracterização de cargas de trabalho para predição do comportamento de tarefas paralelas. As demais seções estão organizadas do seguinte modo: na seção 2 são apresentados os principais trabalhos relacionados; na seção 3 a técnica de caracterização para predição do comportamento de tarefas paralelas; na seção 4 são apresentados e analisados os principais resultados; e por fim, na seção 5 são apresentadas as principais conclusões deste trabalho.

## 2. Trabalhos Relacionados

Nesta seção destacamos os trabalhos relacionados ao escalonamento com informação [Góes e Martins, 2004], análise de informações de cargas de trabalho [Feitelson 2007 e Gmach et al 2007] e técnica de caracterização de carga de trabalho [Elnaffar e Martins 2006].

Elnaffar e Martins (2006) apresentam a aplicação de uma abordagem dinâmica e incremental que explora características de escalonamento em aplicações paralelas. Nesse processo são avaliadas diversas características das tarefas (dia da submissão, tempo de chegada, tempo de execução da aplicação, estimativa do usuário para o tempo de execução da aplicação, entre outras). Utiliza-se o aprendizado baseado em instâncias para obtenção de conhecimentos prévios sobre as características das tarefas.

Góes e Martins (2004) propõem o escalonador com informação RGSA (*Reconfigurable Gang Scheduling Algorithm*). O RGSA visa obter um escalonamento de tarefas que se adapta às variações das arquiteturas paralelas e da carga de trabalho. Para isso, o algoritmo necessita de informações confiáveis das tarefas para entrada de dados do escalonador. Este estudo é complementar à proposta do escalonador RGSA


Nesse contexto de obtenção e utilização de informações, Feitelson (2007) investiga a modelagem de comportamento de cargas de trabalho e constata que uma carga pode ser modelada em distribuições que são significativamente diferentes das distribuições que seriam observadas em intervalos mais longos. Essa constatação baseia-se na análise dos desvios máximo e médio das distribuições em relação a intervalos de tempo e rastros diferentes. O estudo foi norteado pelo objetivo de mensurar variações e gerar modelos simplificados representativos de cargas reais. Os resultados indicam que, em uma carga de trabalho existem dados que possuem razoável semelhança entre si se observados em pequenos intervalos de tempo, diferenças maiores podem ser percebidas ao se analisar longos períodos. Isso indica que ocorrem variações na carga de trabalho ao longo do tempo.

Gmach (2007) realiza um estudo de caso com dados de seis meses de processamento de 139 aplicações. A descoberta de padrões utiliza histogramas de períodos (*periodogram*) e uma função de co-relação entre as variáveis. Por fim ele constata que os rastros (ou históricos de dados) de supercomputadores podem ser utilizados para caracterizar padrões de demanda em cargas de trabalho e, então, gerar modelos sintéticos com potencial de predição de demandas futuras.

Um exemplo de técnica de caracterização de cargas de trabalho é a proposta de caracterização de cargas de trabalho de máquinas paralelas para extração de informações utilizadas pelo escalonador RGSA [Santos e Góes 2007]. São apresentados resultados obtidos em testes realizados com um rastro de supercomputador. Neste trabalho, propõem-se complementos e adaptações nessa técnica, com o propósito de dotá-la de capacidade de predição comportamento de tarefas. Verifica-se a capacidade de representação do modelo de tarefas em relação aos dados originais e a verificação do modelo de tarefas para a predição de comportamento de tarefas futuras.

### 3. Técnica de Caracterização

O princípio básico da técnica [Santos e Góes 2007] é gerar um modelo simplificado da carga de trabalho baseado no tempo de submissão, tempo de execução e no número de processos. O processo para gerar o modelo da carga de trabalho pode ser sumarizado em 3 etapas. Na primeira etapa, as tarefas são extraídas de um histórico (rastros) e classificadas pelo número de processos e tempo de execução em: L (*Low* – baixo) e H (*High* – Alto), as quatro combinações possíveis são apresentadas na Figura 1. O processo de classificação de tarefas utiliza a mediana, medida estatística de tendência central, para dividir as classes H e L, como um *threshold*, para classificar as tarefas. É utilizada a mediana porque é desejado que H e L tenham o mesmo número de tarefas, para que a caracterização seja menos sensível a *outliers*.



**Figura 1. Representação Gráfica da Classificação das Tarefas**

Na segunda etapa, após classificadas, as tarefas são agrupadas pelo dia da semana e hora do dia em que foram submetidas (Tabela-1).

**Tabela 1. Agrupamento pelo Dia da Semana e Hora do Dia**

		Dia da Semana	
Horas do Dia	0		
	1		
	2		
	...		
	22		
	23		

Na terceira etapa, calcula-se a frequência das tarefas, em cada uma das classes (HH, HL, LL e LH), que foram submetidas em cada dia da semana e cada hora do dia. Neste trabalho propõe-se estimar a probabilidade de ocorrência de tarefas, de cada classe e em

cada hora do dia, através do método de aproximação pela frequência, como apresentado na Equação 1, em que  $i$  é uma hora do dia.

$$P(\text{Classe})_i = \left( \frac{\text{Frequência\_Tarefas\_Classe}_i}{\text{Total\_Tarefas}_i} \right) * 100 \quad (1)$$

Em um modelo, tem-se a probabilidade de ocorrência de tarefas de cada classe em cada hora do dia, é possível que horas consecutivas possuam probabilidades muito semelhantes de ocorrência de tarefas em cada classe, o que indica que o comportamento das tarefas não mudou muito de uma hora para outra. A variação existente entre as classes de duas horas consecutivas é dada pela distância entre suas probabilidades de ocorrência, como apresentado na Equação 2, em que,  $i$  e  $j$  são duas horas consecutivas.


$$V(i, j) = | P(\text{Classe})_i - P(\text{classe})_j | \quad (2)$$

Uma medida de comparação entre duas horas é a variação média (VM) entre suas classes (Equação 3). Em cada hora, a soma das probabilidades de ocorrência de tarefas das 4 classes (HH, HL, LL e LH) é igual a 100%, então no pior caso, situação em que duas horas  $i$  e  $j$  são totalmente diferentes, VM entre elas será 50. Isso ocorre, por exemplo, quando se tem probabilidade igual a 100% de ocorrer tarefas HH na hora  $i$  e probabilidade igual a 100% de ocorrer tarefas LL na hora  $j$ .

$$VM(i, j) = \frac{\sum V(i, j)}{\text{Total\_classes}} \quad (3)$$

Dois objetivos são desejados no modelo: (i) Maximizar o agrupamento de horas consecutivas semelhantes, para melhor sintetização do modelo; (ii) Minimizar o desvio gerado pela diferença existente entre as classes das horas agrupadas. O valor de equilíbrio que atende a esses dois objetivos é nomeado constante de agrupamento do modelo (CA), duas horas consecutivas são agrupadas se a variação média (VM) entre elas for menor que CA.

Para definir o valor de CA e realizar o agrupamento de horas o problema foi modelado como um problema de união de vértices em um grafo em linha. Nesse grafo cada hora do dia é um vértice e está ligado, por uma aresta com peso VM à hora que o antecede e à que o precede, exceto o vértice da 0 hora que está ligado apenas ao vértice da 1 hora, e o das 23 horas que está ligada apenas ao das 22 horas (Figura 2).



**Figura 2. Modelagem em Grafo**

Todos os vértices possuem uma estrutura de dados com os valores de P(HH), P(HL), P(LL) e P(LH), que são as probabilidades de ocorrência de tarefas de cada classe naquela hora. A constante de agrupamento CA é uma distância ou variação aceitável entre comportamento das tarefas de dois vértices para que eles possam ser unidos em um único vértice.

A definição do valor de CA se dá através da análise do modelo. Testam-se valores para CA, faz-se o agrupamento de vértice e avalia-se o impacto, do valor testado, no número de vértices do modelo (considerando-se os modelos de todos os dias da semana) e no desvio que o agrupamento gerou, em cada um desses grupos. O processo termina quando se encontra um ponto de equilíbrio, esse ponto de equilíbrio é o valor de CA que atende aos compromissos de maximizar o agrupamento de horas e de minimizar o desvio gerado pelos agrupamentos.

Um valor de CA abaixo do valor de equilíbrio não atende ao compromisso de minimizar o número de vértices. Por outro lado, um valor de CA acima do ponto de equilíbrio minimiza o número de vértices, mas agrupam tarefas com comportamento muito diferente, isso gera um desvio grande entre as tarefas representadas pelo vértice. Deste modo, utilizando-se o valor de equilíbrio CA, obtém-se um modelo sintético (poucos vértices), o que facilita a reconfiguração do escalonador, e vértices com modelos bem definidos por apresentar baixa variação entre as tarefas que o compõe.


Podem-se agrupar dois vértices quando o peso (VM) da aresta entre eles for menor que CA. Quando é realizado o agrupamento de dois vértices, calculam-se novas probabilidades que tratam da ocorrência de tarefas de cada classe naquele grupo de horas. Esse cálculo baseia-se no número de tarefas e nas probabilidades das classes nas horas ou grupos de horas ( $i$  e  $j$ ), que estão sendo agrupadas, como apresentado na Equação 4 (exemplo com a classe HH).

$$P(HH)_{i,j} = \frac{(\text{Total\_Tarefas}_i * P(HH)_i) + (\text{Total\_Tarefas}_j * P(HH)_j)}{\text{Total\_Tarefas}_i + \text{Total\_Tarefas}_j} \quad (4)$$

O agrupamento é um processo iterativo. O Algoritmo 1 apresenta o funcionamento básico do algoritmo de agrupamento de vértices. Seguindo o algoritmo os vértices são unidos como na Figura 3. Ao fim da execução do algoritmo, para cada dia da semana tem-se uma tabela do agrupamento como a Tabela 2.

**Algoritmo 1. Algoritmo de Agrupamento de Vértices**

- 
- 1: Dado um grafo em linha,  $G$ , com 24 vértices
  - 2: Enquanto existir em  $G$  aresta  $e$  com peso VM menor que CA Faça
  - 3:     Escolher a aresta  $e$  de menor VM
  - 4:     Agrupar os vértices incidentes a  $e$
  - 5:         Recalcular P(HH), P(HL), P(LL); P(LH) do vértice gerado com o agrupamento
  - 6:         Recalcular VM das arestas incidentes ao vértice gerado
- 



**Figura 3. Agrupamento de Vértices**

Na Tabela 2, é apresentada a estrutura do modelo de tarefas com horas agrupadas. Nesse modelo LI é o limite inferior do grupo e LS o limite superior. Por exemplo, em um modelo LI pode ser 2 horas e LS 8 horas, o que indica que há um valor de P(HH), P(HL), P(LL) e P(LH) que representa as tarefas submetidas nesse intervalo, das 2 às 8 horas.

**Tabela 2. Exemplo do Modelo de Tarefas com Agrupamento de Horas**

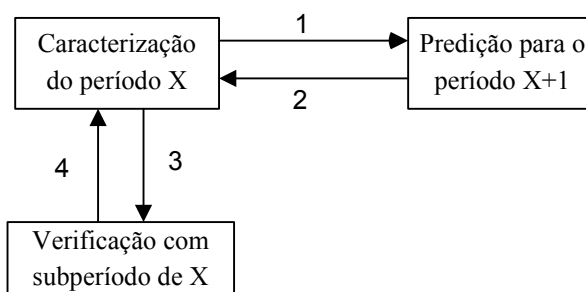
		Dia da Semana			
Grupos de Horas	Intervalo	P(HH)	P(HL)	P(LL)	P(LH)
	$LI_1 - LS_1$				
	$LI_2 - LS_2$				
	...	...	...	...	...
	$LI_{23} - LS_{23}$				
	$LI_{24} - LS_{24}$				

Para descobrir se o modelo de comportamento de tarefas representa bem os dados utilizados para gerá-lo realiza-se a verificação do modelo e para verificar se esse modelo pode ser utilizado para prever o comportamento de tarefas futuras é necessário testar seu potencial de predição. A métrica utilizada para avaliar a verificação e a predição é a semelhança (ou proximidade) entre o modelo caracterizado e o de verificação (para avaliar a verificação) e de predição (para avaliar a predição).

A semelhança entre os modelos é a distância máxima entre os vértices correspondentes dos modelos, que é 50, menos a variação média VM (Equação 3), em que  $i$  é a hora do modelo gerado e  $j$  é o ocorrido no período de verificação ou predição. Por exemplo, se VM entre dois vértices é 20, a semelhança entre eles é 30 (50 menos 20) o que equivale, em termos percentuais, a 60%. Deste modo a semelhança consiste na proximidade existente entre o modelo caracterizado e o modelo de predição ou verificação e pode ser representada, em termos percentuais, pela Equação 5.

$$SM = \frac{\text{Distância\_Máxima} - VM}{\text{Distância\_Máxima}} * 100 \quad (5)$$

Na Figura 4 é descrito o processo de verificação e predição baseada no modelo de comportamento de tarefas gerado através de dados históricos. Nesse processo faz-se a verificação do modelo gerado e uma análise da predição com o objetivo de verificar a eficácia do modelo.



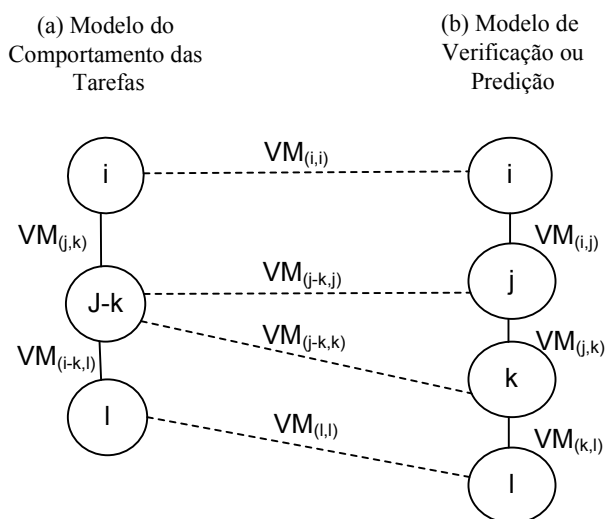
**Figura 4. Processo de Verificação e Predição baseada no Modelo de Comportamento das Tarefas**

Os significados das transições numeradas, na Figura 4, são: 1 é uma verificação da semelhança das tarefas descritas no modelo em relação a uma parte dos dados utilizados para gerá-lo; 2 é o resultado da verificação (Semelhança - SM indicada na Equação 5); 3 é o teste de predição do modelo, consiste em compará-lo com um conjunto de tarefas executadas depois (X+1) do período (X) em que ele foi gerado, o objetivo é verificar se o



comportamento das tarefas nesse período posterior é semelhante ao previsto pelo modelo de tarefas; e, por fim, 4 é o resultado do teste de predição que retorna para a caracterização da semelhança (SM) entre o modelo de tarefas previsto e as tarefas realmente ocorridas.

Na Figura 5, apresenta-se o modelo de comportamento das tarefas (a) e modelo verificação ou predição (b). Nessa figura, as arestas desenhadas com linhas pontilhadas referem-se a variações entre vértices adjacentes em modelos diferentes e as arestas e VM desenhados com linhas contínuas indicam as variações existentes entre vértices adjacentes em um mesmo modelo.



**Figura 5. Grafo de Verificação e Predição baseada no Modelo do Comportamento das Tarefas**

Na Figura 5, o modelo de comportamento das tarefas é o modelo de referência para verificação e/ou predição, uma vez que ele constitui a informação que se tem sobre um dado período. Por exemplo, o vértice  $j-k$ , do modelo de caracterização, possui informações sobre o comportamento das tarefas nos períodos  $j$  e  $k$ , quando for necessário fazer predição de um período  $j$  ou  $k$  podem-se utilizar essas informações ( $j-k$ ). O VM entre as informações de  $j-k$  que foram utilizadas e do  $j$  ou  $k$  que realmente ocorreram é uma medida de avaliação do modelo de comportamento das tarefas.

Em síntese, essa técnica de caracterização de comportamento de tarefas para predição utiliza da teoria de grafos e análises estatísticas, de dispersão e tendência central, para prever (ou predizer) comportamentos de tarefas paralelas. A caracterização do modelo de tarefas e do modelo de verificação e a predição são realizadas utilizando-se cargas de trabalho de tarefas (armazenadas em rastros), uma parte dos dados é utilizada na caracterização verificação e outra parte é utilizada na predição.

#### 4. Apresentação e Análise dos Resultados

Os testes deste trabalho foram realizados em um computador pessoal (processador Pentium IV e 2 Gbytes de memória RAM). A ferramenta de desenvolvimento utilizada foi o *ActiveState ActivePerl 5.6* para a linguagem *Perl*. Para avaliar a técnica proposta realizou-se um estudo de caso com três rastros de supercomputadores reais obtidos no site < <http://www.cs.huji.ac.il/labs/parallel/workload/logs.html> >:

(i) *The HPC2N Log (HPC2N)*, Cluster Linux, o rastro contém 527.371 tarefas executadas entre julho de 2002 a janeiro de 2006, o número de nodos não é descrito no rastro;

(ii) *The Los Alamos National Lab (LANL) CM-5 log*, sistema com 1024 nodos CM5, o rastro contém 201.384 tarefas executadas entre outubro 1994 e setembro de 1996;

(iii) *The San Diego Supercomputer Center (SDSC) Blue Horizon log*, sistema com 144 nodos IBM com 8 processadores por nodo, o rastro contém 250.440 tarefas executadas entre abril de 2000 a janeiro de 2003.

Na caracterização, utilizam-se dados da carga de trabalho, armazenados no rastro, para gerar o modelo de comportamento das tarefas daquela carga de trabalho e na predição utiliza esse modelo de comportamento para estimar o comportamento de uma carga futura. No estudo de caso, caracterizou-se a carga de trabalho, período de janeiro a dezembro, de cada rastro para geração do modelo de comportamento.


No rastro LANL modelou-se o ano de 1995 com 66.560 tarefas, no SDSC o ano de 2001 com 86.277 tarefas e em HPCN o ano de 2004 com 113.724 tarefas. Testou-se o potencial de predição do modelo com o primeiro semestre do ano seguinte.

Na Tabela 3, avaliam-se valores para constante de agrupamento CA na caracterização do rastro LANL – CM5. Percebe-se que à medida que CA aumenta o número de grupos diminui. O número de grupos, por semana, tende a 7, situação em que se tem um único grupo de 24 horas para cada dia da semana. Já a variação média (VM) entre as horas do modelo aumenta à medida que se aumenta a CA, isso porque aumenta a amplitude dos grupos admitindo-se tarefas de características mais variadas.

Na Figura 6 apresenta-se a taxa de redução do número de grupos (NG) e a de crescimento do VM ao se variar CA. Percebe-se, pela Figura 6, que o ponto de equilíbrio entre o número de grupos e a VM é a variação de 7,5 para 10, portanto, para essa carga e período, o valor para CA igual a 10 atende aos objetivos de maximizar o número de grupos e minimizar o desvio gerado por esse agrupamento.

**Tabela 3. Avaliação da Constante de Agrupamento (LANL)**

CA	Número de Grupos	VM
2,5	153	0,09
5	108	0,70
7,5	72	1,51
10	39	2,64
12,5	23	3,56
15	13	4,89



**Figura 6. Avaliação da CA na caracterização do rastro LANL-CM5**

As informações, da Tabela 3 e Figura 6, indicam que ao considerar CA maior que 10, a partir desse valor a taxa de redução de grupos diminui e tende a aumentar a variação entre os dados agrupados. Por outro lado, ao se aplicar uma CA menor que 10 o modelo gerado foge ao objetivo de minimizar o número de grupos. Na Figura 6, são avaliadas as taxas de redução do número de grupos (NG) e de aumento da variação média VM. Observa-se que a taxa de redução de VM caiu na variação de CA de 10 para 12,5, isso ocorreu porque VM aumenta (Tabela 1), mas esse aumento se dá em uma taxa um pouco menor em relação à observada na variação de CA de 7,5 para 10.

Na Figura 7 são apresentadas as classes de tarefas das segundas-feiras de 1995 (LANL) e na Figura 8 o modelo agrupado com a CA = 10. A comparação gráfica indica que ocorreu redução do volume de dados sem ruir as características fundamentais da carga. A VM ao se gerar o modelo agrupado para a segunda-feira é 2,66.




Figura 7. Tarefas das segundas-feiras de 1995 do rastro LANL-CM5

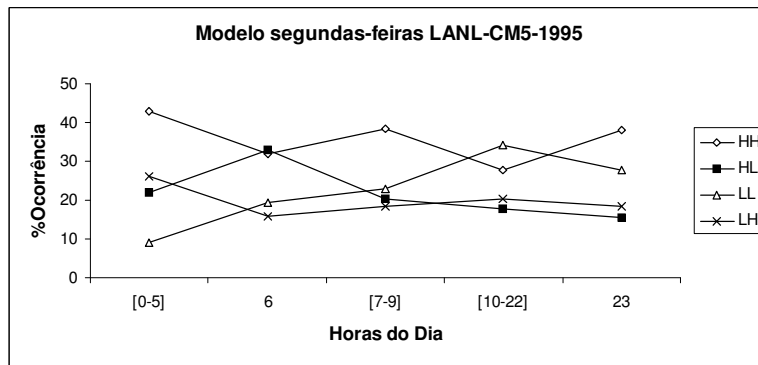



Figura 8. Modelo das segundas-feiras de 1995 do rastro LANL-CM5


Na Figura 9 são apresentados os resultados da verificação do modelo gerado com tarefas de todo o ano de 2004 (66.429 tarefas) da carga de trabalho HPC2N. Verificou-se o modelo gerado com variação da CA: 2,5; 5; 7,5; 10; 12,5 e 15 para os períodos: 2, 4, 6, e 8 meses a partir do primeiro dia do ano de 2004. Constatou-se que a CA interfere pouco na VM entre os modelos gerados na caracterização (isso também foi percebido nas previsões, Figura 10) o contrário do período que sempre possui relevância.

Como esperado, a VM entre os modelos reduz à medida que o período de verificação se aproxima ao utilizado na geração do modelo, isso ocorre porque aumenta o número de tarefas relacionadas o que torna a média mais apurada.



**Figura 9. Verificação do modelo de tarefas do rastro HPC2N-2004**

Testou-se a capacidade de predição dos modelos gerados com todas as cargas de trabalho. Na Figura 10 estão apresentados dados da predição de comportamento para a carga de trabalho SDSC em 2002 com base em informações estimadas pelo modelo de tarefas de 2001. Nesse teste variam-se os períodos de predição e as CA.




**Figura 10. Análise do potencial de predição do modelo de tarefas SDSC 2001**

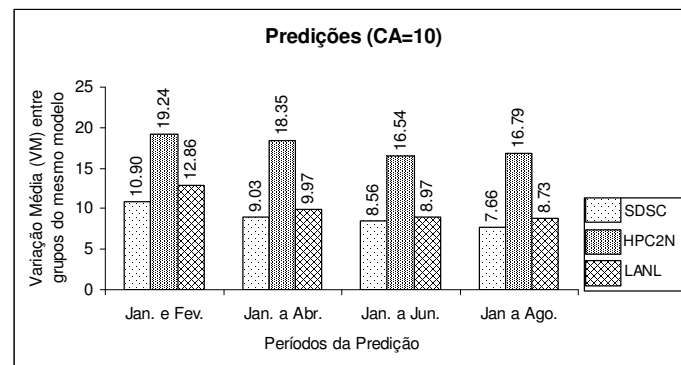
Percebe-se que a CA interfere pouco no desvio interno dos grupos do modelo, para essa carga a predição ficou melhor à medida que se aumentou o período de incidência. O mês de janeiro é instável em relação ao modelo, mas a partir de fevereiro estabiliza-se com VM próximo a 11, o que significa que as características das tarefas executadas no primeiro semestre de 2002 são bem parecidas com as de 2001.

Na Figura 11 é apresentada uma comparação das verificações realizadas para os rastros analisados e na Figura 12 apresentamos os resultados das predições. A verificação foi realizada com parte dos dados utilizados na geração do modelo e a predição com dados do ano seguinte, os períodos da verificação e predição estão indicados pelos meses, o ano

varia dependendo da carga: HP2N caracterização de 2004 e predição de 2005; SDSC caracterização de 2001 e predição de 2002 e LANL caracterização de 1995 e predição de 1996. É irrelevante para este trabalho que os anos dos rastros sejam diferentes, uma vez que o foco da análise é o potencial de predição da técnica.



**Figura 11. Verificação dos Modelos Gerados**



**Figura 12. Análise do Potencial de Predição dos Modelos Gerados**

Em média, a carga HPC2N apresentou bom resultado na verificação, no entanto, a predição não foi tão boa, VM mínimo obtido foi de 16,79. Isso devido à mudança de comportamento da carga de um ano para outro, por exemplo, de janeiro a agosto de 2004 executaram 84.509 tarefas, já em 2005 no mesmo período só executaram 55.944 tarefas.

A carga LANL apresentou bom comportamento tanto na caracterização, quanto na predição. O comportamento da carga não se altera muito de período para período, mas em cada período as tarefas têm características muito distintas de modo que em qualquer agrupamento gera-se um VM não muito pequeno.

A carga SDSC, por sua vez, é muito regular em 2001 e apresenta boa semelhança com 2002. Por exemplo, o modelo de tarefas gerado para 2001 possui 85% de semelhança com as tarefas executadas de janeiro a agosto de 2002. É um bom percentual considerando-se que a estimativa é baseada em dados históricos e que, normalmente, ocorrem algumas variações no comportamento das tarefas.

## 5. Conclusão e Trabalhos Futuros

Neste trabalho propomos, implementamos, verificamos e testamos uma técnica de caracterização de carga de trabalho para predição de tarefas futuras. Concluímos que a técnica desenvolvida, além de caracterizar e verificar os comportamentos típicos, em um conjunto de tarefas de uma carga trabalho, é capaz, também, de prever um comportamento futuro em cargas regulares. Isso quer dizer que através do modelo gerado para um período estimar o comportamento do conjunto de dados em um período posterior ao utilizado na caracterização, uma vez constatada a regularidade da carga.

Essa capacidade de predição, da técnica, supre a necessidade de um método automático de obter as informações confiáveis para o escalonador RGSA. Destacamos duas contribuições deste trabalho para a área em estudo: (i) Desenvolvimento de um processo de caracterização e análise de dados, de rastros, capaz de sintetizá-los em modelos de carga de trabalho, análise dos modelos gerados através de métodos estatísticos que identifica a recorrência e a semelhança com comportamento de tarefas futuras; (ii) Desenvolvimento de uma técnica de caracterização para predição de informações no formato que o escalonador reconfigurável (RGSA) necessita para teste e aplicação em ambiente real.

Como trabalhos futuros, nós destacamos o teste e a avaliação da caracterização e escalonamento em um ambiente real. Destacamos, também, o desenvolvimento de um algoritmo de caracterização adaptativo, que evolua aprendendo com os resultados das predições realizadas.

## Referências

- Cirne, W.; Brasileiro, F.; Paranhos, D.; Góes, L. F. W. e Voorsluys, W., (2007) “On the efficacy, efficiency and emergent behavior of task replication in large distributed systems”, *Parallel Computing*, pp. 213-234.
- Elnaffar, Said e Martin, Pat (2006) “Techniques and a Framework for Characterizing Computerizing Computer Systems Workloads”. IEEE.
- Feitelson, D. (2007) “Locality of Sampling and Diversity in Parallel System Workloads” *Proceeding do ACM SIGMETRICS*, pp. 53-63.
- Gmach, D. Rolia, J. Cherkasova, L e Kemper, A. (2007) “Workload Analysis and Demand Prediction of Enterprise Data Center Applications” pp. 171-180.

- Góes, L. F. W. e Martins, C. A. P. S., (2004) “Reconfigurable Gang Scheduling Algorithm”, 10th Workshop on Job Scheduling Strategies for Parallel Processing, Lecture Notes in Computer Science, New York.
- Jain, R. (1991) “The art of computer systems performance analysis: techniques for experimental design, measurement, simulation, and modeling”. New York: J. Wiley.
- Lee, C.B. (2004) “Are user runtime estimates inherently inaccurate? 10th Workshop on Job Scheduling Strategies for Parallel Processing.
- Santos, L. P. e Góes, L. F. (2007) “Técnica de Caracterização de Cargas de Trabalho para Extração de Informações Utilizadas pelo Escalonador Reconfigurável de Tarefas” Workshop de Sistemas Computacionais de Alto Desempenho (WSCAD).
- Senger, L. J. e Santana, M. J. (2004) “Escalonamento de processos: uma abordagem dinâmica e incremental para a exploração de características de aplicações paralelas” Tese de Doutorado, Universidade de São Paulo – USP.