

Descoberta e Predição de Comportamento de Tarefas Paralelas através da Caracterização de Padrões em Cargas de Trabalho

Lesandro Ponciano dos Santos¹, Luís Fabrício W. Góes²
Pontifícia Universidade Católica de Minas Gerais
lesandrop@yahoo.com.br¹, lfwgoes@pucminas.br²

Resumo

Neste trabalho descobrimos e predizemos comportamento de tarefas paralelas, através da caracterização de padrões, para subsidiar a reconfiguração do escalonador RGSA. Na caracterização, os padrões baseiam-se em dados do tempo de submissão, número de processos e do tempo de execução das tarefas paralelas. O principal objetivo do trabalho é descobrir e analisar períodos em que os padrões se repetem. Na predição, utilizamos os padrões descobertos para estimar o comportamento de novas tarefas paralelas que, futuramente, serão submetidas ao sistema. Realizamos um estudo de caso com dois rastros (históricos) de supercomputadores. Como resultado, identificamos, por exemplo, em alguns períodos, que novas tarefas submetidas ao sistema possuíam comportamento 77% semelhante ao estimado com dados histórico.

1. Introdução

Nos últimos anos, têm aumentado as necessidades dos usuários de sistemas computacionais em relação ao custo, tempo e qualidade de serviços [5,8,9]. Para suprir essas necessidades, tem-se desenvolvido aplicações cada vez mais complexas, em que as tarefas, geralmente, consomem mais recursos de processamento e memória e realizam mais operações de entrada e saída [1,3,4]. Em contrapartida, têm surgido pesquisas que visam aumentar o desempenho dos sistemas computacionais, entre esses as arquiteturas paralelas e distribuídas.

Nessas arquiteturas, tem-se estudado meios de obter o máximo de desempenho computacional através da otimização de componentes de software e hardware [5,6,2]. Destacamos, entre esses componentes, o escalonador de tarefas. O escalonador de tarefas tem a função de escalonar (distribuir) os processos de uma tarefa entre os processadores disponíveis na arquitetura paralela.

Pode-se classificar o processo de escalonamento, quanto ao conhecimento da carga à qual incide, em: escalonamento sem informação [1] e escalonamento com informação [5]. No escalonamento sem informação a distribuição das tarefas entre os processadores baseia-se, geralmente, em políticas fixas de tempo, ordem de chegada e/ou fila de prioridade [5,2].

De outro modo, o escalonamento com informação baseia-se em características das tarefas da carga de trabalho para definir um processo mais adequado, para realizar o escalonamento. O escalonamento com informação possibilita ganho de desempenho quando comparado com escalonamento sem informação [5].

Neste trabalho, destacamos o escalonador com informação: *Reconfigurable Gang Scheduling Algorithm (RGSA)*. O RGSA é um algoritmo de escalonamento reconfigurável [8], ele parte de um conjunto de políticas de escalonamento pré-programadas, seleciona a melhor política de acordo com as características da carga de trabalho, e aprimora o seu desempenho à medida que se adapta a mudanças de comportamentos dessa carga.

Informações confiáveis são essenciais no escalonamento com informação, porque informações incorretas podem prejudicar o desempenho do sistema [7]. Um método de se obter informações sobre as tarefas, de uma carga de trabalho, são os usuários fornecê-las, mas esse não é um método confiável [7]. Outro método é a caracterização de rastros (históricos de execução de tarefas), que possibilita construir um modelo de desempenho das tarefas e utilizá-lo como informação confiável [6].

No entanto, para o escalonamento com informação, além de modelar o comportamento das tarefas é necessário identificar os períodos em que esses comportamentos ocorrem e os períodos em que eles se alteram, e o quanto as informações obtidas em um período são válidas para predição de períodos subsequentes [4]. Assim, o problema desse trabalho é a descoberta, modelagem e predição de comportamentos de tarefas paralelas ao longo do tempo. Para suprir a demanda de

informações confiáveis do escalonador RGSA, os modelos gerados devem ser constituídos de uma estrutura de dados com informações do tempo de submissão e de execução e do número de processos das tarefas.

Deste modo, o principal objetivo, deste trabalho, é descobrir e analisar períodos em que os padrões de comportamento de tarefas paralelas são semelhantes. Os objetivos específicos são: modelar os padrões de comportamentos e avaliar seu potencial de predição de novas tarefas paralelas. Os testes apresentados neste trabalho foram realizados com dois rastros de supercomputadores reais.

Este artigo está organizado do seguinte modo: na seção 2 é apresentado o estudo dos trabalhos relacionados; na seção 3 a técnica de modelagem e predição de comportamentos de tarefas paralelas; seção 4 os resultados experimentais; na seção 5 a conclusão e trabalhos futuros e, por fim, na seção 6 as principais referências bibliográficas.

2. Trabalhos Relacionados

Nesta seção destacam-se os seguintes trabalhos relacionados: algoritmo reconfigurável de tarefas [5]; análise de comportamentos em cargas de trabalho [3,4]; técnica de caracterização de cargas de trabalho [9].

O algoritmo reconfigurável de escalonamento paralelo de tarefas RGSA [5] 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.

Para a seleção das políticas de escalonamento, o RGSA utiliza informações sobre a hora e o dia de submissão, número de processos e tempo de execução das tarefas [5]. Este trabalho é complementar à proposta e implementação do RGSA [5], e visa obter as informações confiáveis que esse escalonador necessita.

A análise do comportamento de cargas de trabalho ao longo do tempo e em espaços geográficos distintos [3] indica que essas cargas variam com os intervalos de tempo e espaços geográficos diferentes. Uma carga de trabalho durante intervalo de tempo pequeno pode conduzir a distribuições que são, significativamente, diferentes das obtidas em intervalos mais longos, assim como, em locais diferentes também diferem uma das outras [3]. Essas constatações são verificadas com a análise dos desvios máximo e médio das distribuições em relação a intervalos de tempo e rastros diferentes. A percepção dessas variações motiva o desenvolvimento de sistemas adaptáveis que se ajustam à carga de trabalho e que aprendem com ela [3].

A constatação das variações nas distribuições da carga de trabalho em períodos e locais diferentes e a

necessidade de adaptabilidade do sistema a essas variações são informações muito importantes para este trabalho. Nas cargas de trabalho, também, são percebidos alguns padrões de demanda de aplicações [4] e os sistemas adaptáveis devem prever essas demandas para obter melhor desempenho.

Para atender à necessidade de adaptação do sistema à carga de trabalho e, então, realizar a predição da demanda é necessário obter informações confiáveis sobre essa carga. A técnica de caracterização [9] extrai informações do tempo de submissão, número de processos e tempo de execução das tarefas para entrada de dados no escalonador RGSA. A técnica foi testada em um estudo de caso realizado com o rastro LANL-CM5-1994-3 do supercomputador do *The Los Alamos National Lab*. Foram analisadas 66.560 tarefas executadas durante o ano de 1995.

Neste trabalho, optou-se por adaptar a técnica de caracterização [9], a fim de dotá-la de métodos de descobrir e prever comportamentos de tarefas de uma carga de trabalho através da percepção de padrões. A escolha, dessa técnica, se deu por sua compatibilidade com a estrutura de dados requerida pelo RGSA.

3. Técnica de Modelagem e Predição de Tarefas Paralelas

A técnica de caracterização [9] classifica as tarefas da carga de trabalho, pelo tempo de execução e número de processos em: H (*high* - quando o valor é superior à mediana) e L (*low* - quando o valor é menor ou igual à mediana). Deste modo, formam-se quatro combinações possíveis, como apresentado na Figura 1.

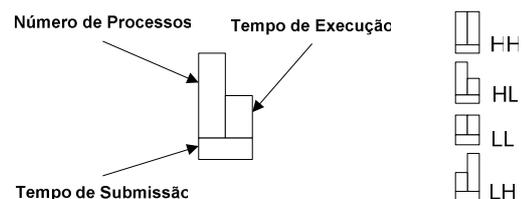


Figura 1 – Classificação das Tarefas

As tarefas são classificadas, também, pelo tempo de submissão em: dia da semana e hora do dia em que foram submetidas. Uma vez classificadas, calcula-se a frequência relativa de tarefas de cada classe (HH, HL, LL e LH) em cada hora do dia e dia da semana, como o modelo apresentado na Tabela 1. Para fim de predição, faz-se a aproximação da probabilidade pela frequência relativa de modo a estimar, para cada hora do dia em cada dia da semana, a probabilidade de ocorrerem tarefas de cada classe i (Equação -1).

Tabela 1. Modelo de Classificação e Predição Tarefas

HORA	DIA DA SEMANA			
	P(HH)	P(HL)	P(LL)	P(LH)
0				
1				
⋮	⋮	⋮	⋮	⋮
22				
23				

$$P(i) = \frac{\text{Frequência_de_Tarefas}_i}{\text{Total_de_Tarefas}} \quad (1)$$

O comportamento do modelo de tarefas é medido através do cálculo da variação média (VM) (Equação 2), entre os modelos de classificação e predição tarefas (Tabela 1). 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 tem-se probabilidade igual a 100% de ocorrer tarefas HH na hora i e probabilidade igual a 100% de ocorrer tarefas LL na hora j .

$$VM(i, j) = \frac{\sum(\text{classe } i - \text{classe } j)}{\text{Total_classes}} \quad (2)$$

A técnica de predição modela padrões de comportamento em períodos semanais e mensais, além dos dias da semana e horas do dia. A análise da variabilidade das tarefas, nesses períodos, é realizada através do cálculo do coeficiente de variação (CV) (desvio padrão dividido pela média) do tempo de execução e número de processos. O coeficiente de variação semelhante, em períodos distintos, indica semelhança de comportamento quanto à dispersão dos dados.

Assim, com a indicação do comportamento das tarefas e dos períodos em que há baixa e alta semelhança dos dados, o escalonador de tarefas RGSA pode utilizar o modelo de classificação e predição de tarefas como uma estimativa de tarefas futuras. As análises de predição são realizadas medindo-se o percentual de semelhança média entre o modelo estimado e o que ocorreu de fato.

A semelhança entre os modelos é a distância máxima entre as classes (HH, HL, LL e LH) de cada hora dos modelos (Tabela 1), que é 50, menos a variação média VM (Equação 2), 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 duas horas 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 3.

$$SM = \frac{\text{Distância_Máxima} - VM}{\text{Distância_Máxima}} * 100 \quad (3)$$

A técnica foi implementada em linguagem Perl utilizando o ambiente Active State Active Perl 5.6 e alguns procedimentos em linguagem C++ utilizando a ferramenta DEV C++ 4.9.9.2.

4. Resultados Experimentais

Para avaliar a técnica de predição realizou-se a modelagem e predição em dois rastros de máquinas paralelas: (i) rastro SDSC-DS-2004-1, do computador paralelo IBM p655/p690, instalado no *San Diego Supercomputer Center (SDSC) DataStar*. Desse rastro foram utilizadas 42.484 tarefas executadas entre abril e outubro de 2005 e (ii) rastro SHARCNET-2005-1, de um *grid* locado em *Sharcnet Grid*. Desse rastro foram utilizadas 624.035 tarefas executadas entre abril e outubro de 2006. Os rastros foram em obtido no site <<http://www.cs.huji.ac.il/labs/parallel/workload/>>.

Foram realizados testes e análises variando o período de modelagem e de predição, mas por limitações de espaço serão apresentados, apenas, alguns desses resultados. O primeiro teste é a caracterização de um mês para prever o mês seguinte (Figura 2). Percebe-se, que as tarefas apresentam semelhança superior a 50%, na maioria dos testes de predição, e que nos melhores casos, essa semelhança, aproxima-se a 70%. É um bom nível de semelhança uma vez que, geralmente, ocorrem algumas variações no comportamento da carga [3].

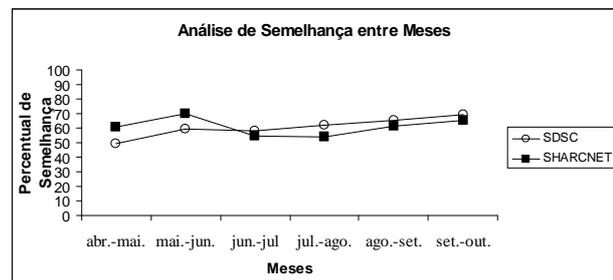


Figura-2 Semelhança entre Meses

Na Figura 2, o percentual de semelhança da predição para o modelo ocorrido, caiu de junho para julho. Isso ocorreu porque, em junho, foram submetidas 52.551

tarefas e em julho 95.118, aumento de 81% no número de tarefas.

Ainda no Figura 2, percebeu-se que a menor semelhança entre o modelo de predição e o realmente ocorrido no testes de usar dados históricos de abril para prever comportamentos de maio 49,22% (SDSC). Isso ocorre porque há alta dispersão ou variabilidade dos dados no mês de maio (Figura 3), o que o torna menos semelhante à estimativa realizada com dados de Abril.

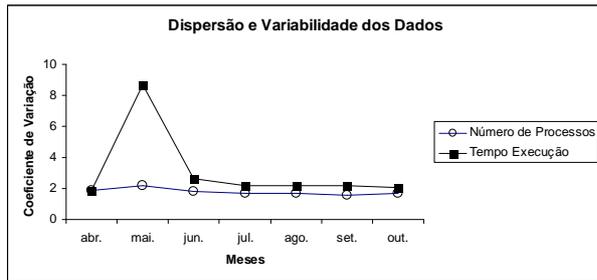


Figura 3 – Dispersão ou Variabilidade dos Dados

A técnica de modelagem e predição identifica semelhança e diferenças existentes nos dados de execuções armazenadas em histórico. Na tabela 2, apresentam-se os dados da modelagem (Mod) de um mês para predição (Pred) do mês seguinte e indica o percentual de semelhança para cada dia da semana. Na Tabela 2 estão destacados, em **negrito**, as semelhanças superiores 70% e, em sublinhado, as semelhanças menores que 50%. A avaliação dos pontos de semelhanças e diferenças é uma avaliação da carga de trabalho, portanto, variam de acordo com os padrões e similaridades dos dados nela existentes.

Tabela 2. Semelhança entre o modelo Predito e o Ocorrido (rastros Sharcnet)

Mod.	Pred.	Percentual de semelhança entre os dias da semana							
		D	S	T	Q	Q	S	S	
Abr.	Mai.	73	56	<u>43</u>	65	63	58	65	
Mai.	Jun.	77	62	71	71	71	66	71	
Jun.	Jul.	46	57	53	56	69	49	55	
Jul.	Ago.	55	51	58	57	52	49	58	
Ago.	Set.	65	61	63	57	56	66	60	
Set.	Out.	50	63	76	74	67	61	64	

5. Conclusão e Trabalhos Futuros

Neste artigo, descobrimos e predizemos comportamentos de tarefas paralelas através da modelagem de padrões. Percebeu-se pelos trabalhos relacionados que existem comportamentos constantes variáveis nas cargas de trabalho e propuseram-se métodos

de modelar esses padrões para prever comportamentos futuros.

Nos testes realizados, detectaram-se padrões de comportamento, diversas situações em que esses padrões se repetiram com muita semelhança e, também, situações em ocorreram mudanças de comportamento resultando em baixa semelhança. Os resultados obtidos são importantes para obtenção de informações confiáveis para o escalonador RGSA.

Como trabalhos futuros propõe-se a implementação do processo de predição em um ambiente de escalonamento reconfigurável a fim de avaliar a reconfiguração do escalonador às variações da carga de trabalho.

6. Referências

- [1] Cirne, W.; Brasileiro, F.; Paranhos, D.; Góes, L. F. W. e Voorsluys, W., "On the efficacy, efficiency and emergent behavior of task replication in large distributed systems", *Parallel Computing*. 2007
- [2] Senger, L. J. e Santana, M. J.. "Escalonamento de processos: uma abordagem dinâmica e incremental para a exploração de características de aplicações paralelas" Tese de Doutorado, Universidade de São Paulo – USP. 2004.
- [3] Feitelson, D. "Locality of Sampling and Diversity in Parallel System Workloads" pp. 53-63. 2007.
- [4] Gmach, D. Rolia, J. Cherkasova, L e Kemper, A. "Workload Analysis and Demand Prediction of Enterprise Data Center Applications" pp. 171-180. 2007.
- [5] Góes, L. F. W. e Martins, C. A. P. S., "Reconfigurable Gang Scheduling Algorithm", 10th Workshop on Job Scheduling Strategies for Parallel Processing, Lecture Notes in Computer Science, New York. 2004.
- [6] Jain, R. "The art of computer systems performance analysis: techniques for experimental design, measurement, simulation, and modeling". New York: J. Wiley, c1991.
- [7] Lee, C.B., et al. "Are user runtime estimates inherently inaccurate?" 10th Workshop on Job Scheduling Strategies for Parallel Processing. 2004.
- [8] Martins, C. A. P. S.; Ordonez, E. D. M.; Corrêa, J. B. T. e Carvalho, M. B., "Computação Reconfigurável: Conceitos, Tendências e Aplicações", Jornada de Atualização em Informática, Brasil. 2003.
- [9] Santos, L. P. e Góes, L. F. "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), 2007.