Análise Automática de Desempenho Baseada em Aprendizagem de Máquina

Flavio Alles Rodrigues, Lucas Mello Schnorr

[1]Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

{farodrigues,schnorr}@inf.ufrgs.br

Resumo. *Análise de desempenho deve escalar para ser informativa. Uma abordagem para atingir tal objetivo é a automação deste processo. Porém, ferramentas que representam o estado da arte em análise automática possuem expectativas estáticas com relação às aplicações e ao ambiente sob análise. Tais expectativas podem limitar o impacto da análise de desempenho. Técnicas de aprendizagem de máquina são uma solução em potencial para tais limitações.*

1. Introdução

Tendências atuais em sistemas computacionais paralelos (*i.e.* aumento no número de processadores, maior heterogeneidade e elevação no consumo de energia) tornam o trabalho de programar estes sistemas desafiador. Escalar uma aplicação de forma que esta utilize eficientemente múltiplos e, eventualmente, distintos processadores é uma tarefa difícil. Por esta razão, ferramentas de análise de desempenho são essenciais para que o programador utilize corretamente sistemas computacionais paralelos.

As técnicas de análise de desempenho mais comumente utilizadas são *profiling* e aquelas baseadas na visualização de dados. Uma terceira técnica de análise envolve a transformação dos dados coletados através de algum algoritmo de agregação ou agrupamento (reduzindo assim a quantidade de informação). Então, após a transformação, os dados são analisados através de alguma técnica de visualização.

A grande desvantagem que estas técnicas apresentam é a falta de escalabilidade. *Profiling* e transformação de dados condensam a informação comportamental da aplicação paralela, gerando perda de informação. Assim, muitos padrões de interesse podem ser perdidos, especialmente em aplicações grandes. Da mesma forma, problemas de escalabilidade estão presentes em todos aspectos da análise visual: o analista que identifica problemas em uma representação composta por uma vasta quantidade de elementos visuais; a ferramenta de análise que produz uma imagem compacta e clara com base em uma grande quantidade de dados; e a tela que possui limites físicos que determinam o que pode ser renderizado em uma única imagem.

2. Análise Automática de Desempenho

Análise automática de desempenho consiste na detecção de padrões de comportamento e problemas de desempenho sem a intervenção do analista. O objetivo é, então, encontrar problemas de desempenho autonomamente e reportá-los ao analista. A vantagem mais evidente da automatização da análise de desempenho é a escalabilidade. A quantidade de dados a ser analisada não é limitada pelo ser humano ou pelo tamanho da tela. O único limitador são os recursos computacionais disponíveis para realizar a análise. Logo, análise automática de desempenho representa uma técnica promissora para o entendimento completo do comportamento de aplicações paralelas de larga escala.

Porém, a avaliação do estado da arte em ferramentas automáticas de análise de desempenho de aplicações paralelas torna evidente que tais ferramentas, ao assumir expectativas estáticas em relação à aplicação e ao ambiente computacional sob investigação, têm uma capacidade limitada de análise [Miller, B.P. et. al. 1995, Gerndt and Ott 2010, Geimer, Markus et. al. 2010]. Tais expectativas se manifestam tanto em relação aos problemas diagnosticados como às máquinas paralelas onde estas aplicações são executadas.

Ferramentas de análise automática somente diagnosticam problemas de desempenho previamente estabelecidos. Situações desconhecidas que prejudiquem o desempenho da aplicação não serão descobertas. Além disso, estas ferramentas assumem que o ambiente onde as aplicações sob análise estão executando é homogêneo. Tal suposição não pode ser garantida, especialmente considerando a tendência corrente em sistemas paralelos onde máquinas são compostas por processadores com características distintas. Portanto, é fundamental o estudo de técnicas de análise automática flexíveis, capazes de aprender as características do sistema e, assim, adaptar a análise de desempenho a estas.

3. Análise de Desempenho Baseada em Aprendizagem de Máquina

Aprendizagem de Máquina consiste em um conjunto de técnicas que possibilitam a extração do algoritmo a partir de dados representativos da tarefa em questão [Alpaydin 2004]. Estas técnicas podem ser classificadas em duas categorias: algoritmos supervisionados e algoritmos não-supervisionados. Algoritmos supervisionados aprendem o mapeamento entre entrada e saída a partir de dados que estabelecem a(s) saída(s) para possíveis entradas. No aprendizado não-supervisionado existem somente dados de entrada; o objetivo é o reconhecimento de padrões nestes dados.

Como não fazem suposições sobre a forma de analisar os dados, técnicas de aprendizado não-supervisionado são uma abordagem em potencial para lidar com os problemas em análise automática. *Clustering* é uma técnica de aprendizado não-supervisionado, onde o objetivo é encontrar agrupamentos nos dados de entrada. Assim, no contexto da análise do desempenho das aplicações paralelas, *clustering* pode ser usado para identificar fases distintas na execução da aplicação; ou, ainda, pode ser utilizado como um meio para procurar irregularidades e ineficiências na computação. Outras técnicas de aprendizagem não supervisionada a serem exploradas na análise automática de aplicações paralelas são *self-organizing maps*, *adaptive resonance theory* e modelos de Markov.

O futuro da nossa pesquisa consistirá na implementação e avaliação de algoritmos de aprendizagem de máquina sobre rastros de eventos gerados por aplicações paralelas com o objetivo de avaliar o desempenho das mesmas.

Referências

Alpaydin, E. (2004). *Introduction to machine learning*. MIT press, Cambridge, USA.

Geimer, Markus et. al. (2010). The scalasca performance toolset architecture. *Conc. & Comp.: Prac. Exp.*, 22(6):702–719.

Gerndt, M. and Ott, M. (2010). Automatic performance analysis with periscope. *Concurrency and Computation: Practice and Experience*, 22(6):736–748.

Miller, B.P. et. al. (1995). The paradyn parallel performance measurement tool. *Computer*, 28(11):37–46.