

Refinamento de Estratégias de Previsão de Demanda de Recursos em Nuvens IaaS

Gustavo José Neves da Silva¹, Rafael Rodrigues Obelheiro²

¹ Acadêmico(a) do Curso de Ciência da Computação – CCT - bolsista PROBIC/UDESC

² Orientador, Departamento de Ciência da Computação – CCT – rafael.obelheiro@udesc.br

Palavras-chave: Computação na Nuvem, Séries Temporais, Previsão de Demanda

Um dos modelos de serviço adotados em nuvens computacionais é o de infraestrutura como serviço (*Infrastructure-as-a-Service*, IaaS), em que recursos computacionais como CPU, memória e rede são disponibilizados para o usuário através de máquinas virtuais e/ou contêineres. No modelo IaaS, o cliente tem controle dos recursos, podendo acomodar o poder computacional às suas necessidades, pagando apenas pelos recursos necessários, gerando dessa forma um menor custo final. No entanto, escolher a melhor combinação de recursos não é uma tarefa trivial, uma vez que é necessário conhecer não apenas a aplicação a ser implantada mas também a sua demanda de recursos.

Visando a prever a demanda de largura de banda de rede de máquinas virtuais em nuvens IaaS, foi proposto por (LACURTS et al. 2014) um algoritmo chamado Cicada, que realiza previsões com base na análise da demanda em um período de tempo pregresso. O algoritmo Escada, introduzido em (MARQUES; OBELHEIRO, 2017), utiliza uma estratégia diferente para estimar a largura de banda necessária, obtendo melhores previsões do que Cicada. O algoritmo de predição usado por Escada, que é o mesmo de Cicada, é chamado de *expert tracking*, e se caracteriza por gerar previsões a partir de uma soma ponderada das observações passadas; o peso de cada observação é atualizado a cada iteração do algoritmo, com base nos erros de previsão. Esse algoritmo possui convergência lenta quando a demanda apresenta sazonalidade. Portanto, a presente pesquisa tem como principal objetivo melhorar o algoritmo de predição para cargas sazonais.

O algoritmo proposto requer uma estimativa do período sazonal da carga, sendo que essa estimativa pode ser aproximada. Tal estimativa pode ser obtida, por exemplo, através da Transformada de Hilbert, disponível no software estatístico R, na biblioteca *forecast*. Com isso, enquanto o número de observações de carga for inferior ao período estimado, o algoritmo gera como predição a observação mais recente. Quando o histórico de observações atingir o período sazonal estimado, o algoritmo passa a adotar a estratégia de *expert tracking* de Cicada e Escada, mas atribuindo o mesmo peso inicial a todas as observações no histórico.

Para avaliar o algoritmo foi sintetizada uma carga com característica sazonal, mostrada na Figura 1. Essa carga é representativa da carga de rede (em intervalos de 1 h) para um servidor que

possui uma demanda de acesso que acompanha o horário comercial: a carga é baixa entre 22:00 e 06:00, começa a aumentar a partir de 07:00, permanece no topo entre 08:00 e 19:00 (com queda às 13:00) e baixa a partir de 20:00, retornando ao mínimo às 22:00. Embora a carga não seja exatamente a mesma todos os dias, havendo uma certa variabilidade, percebe-se que esse padrão se repete diariamente, correspondendo a um período sazonal de 24 observações.

Foi gerada uma carga com essas características com duração de 21 dias, e foram obtidas previsões para essa carga usando o algoritmo Cicada e o algoritmo proposto, considerando estimativas de períodos sazonais entre 20 e 28, para avaliar o impacto de imprecisão na estimativa. Realizando a diferença entre cada previsão e a observação correspondente, em módulo, foi calculado o erro absoluto acumulado ao longo dos 21 dias para cada algoritmo. Os valores estão normalizados pelo erro absoluto acumulado do Cicada; percebe-se que, quando o período sazonal é subestimado (ou seja, com menos de 24 observações), o erro foi entre 46,2% e 52,2% superior ao de Cicada. Quando a estimativa é igual ou superior ao período sazonal, o erro absoluto acumulado é quase 30% inferior ao de Cicada, com pouca variação entre os diferentes tamanhos de histórico. A Figura 2 mostra o número de iterações do algoritmo até que o peso da observação correspondente ao período sazonal de 24 atinja um determinado limiar (i.e., quando pelo menos 50% ou 90% da previsão é dada pela observação de 24 períodos atrás). O número de iterações aumenta levemente quanto maior for o tamanho do histórico, mas em todos os casos o algoritmo proposto tem um tempo de convergência aproximadamente 75% menor do que o algoritmo de Cicada. Com isso, percebe-se que, para uma carga sazonal, o algoritmo proposto apresenta previsões com mais qualidade que as oferecidas pelo algoritmo de Cicada.




Fig. 1 Gráfico da carga sintetizada




Fig. 2 Gráfico do número de iterações

Referências

MARQUES, J. A. ; OBELHEIRO, Rafael R. Escada: Predicting Virtual Machine Network Bandwidth Demands for Elastic Provisioning in IaaS Clouds. In: **IEEE International Conference on Cloud and Autonomic Computing (ICCAC)**, 2017, Tucson, AZ. Proceedings of the IEEE International Conference on Cloud and Autonomic Computing (ICCAC), 2017.

LACURTS, K. et al. Cicada: Introducing predictive guarantees for cloud networks. In: **6th USENIX Workshop on Hot Topics in Cloud Computing (HotCloud 14)**. [S.l.: s.n.], 2014.