


Seleção de Provedores de Nuvem através do Auxílio de Aprendizado de Máquina Automatizado

Kauã B. Hopfer¹, Adriano Fiorese¹ 

¹Departamento de Ciência da Computação – Universidade do Estado de Santa Catarina (UDESC)
Joinville – SC – Brazil

kauahopfer@outlook.com, adriano.fiorese@udesc.br

Resumo. *Uma forma de ranqueamento e seleção de provedores de nuvem é apresentada através do uso da função de Aprendizado de Máquina Automatizado (AutoML) da plataforma H2O. É exibido um sistema de ranqueamento que produz uma pontuação para cada provedor de nuvem avaliado. Experimentos realizados com o auxílio da plataforma H2O, apresentaram resultados precisos e mais rápidos quando comparados a alternativa de resolução exata.*

1. Introdução

A computação em nuvem é um tipo de serviço que permite a possibilidade de acesso a recursos computacionais como armazenamento de dados, hospedagem de sistemas, criação, execução e distribuição de software pela internet. Dessa forma com o uso da nuvem, o usuário não precisa se preocupar com a contratação ou compra de servidores e hardwares específicos para dispor desses recursos, apenas com qual provedor de serviço de nuvem escolher. Assim, o cliente precisa apenas alugar o serviço no modo pague-por-uso como uma comodidade similar ao mercado de energia e água [Repschläger et al. 2011]. Assim, a computação na nuvem abstrai para o usuário a complexa infraestrutura e arquitetura interna do provedor de serviço de nuvem [de Moraes et al. 2017]. Entretanto, isso introduz um novo dilema, o problema de tomada de decisão acerca do provedor de nuvem mais adequado para um indivíduo ou organização.

Então, o objetivo do trabalho consiste na automatização desse processo de escolha com o emprego de um sistema de ranqueamento de provedores de serviços de nuvem. Esse sistema de ranqueamento deve produzir uma pontuação para cada provedor avaliado a partir da qualificação dos requisitos exigidos pelo usuário. Assim, o provedor que possuir a maior pontuação final será teoricamente o provedor de nuvem mais apropriado para aquele usuário/organização, conforme os requisitos exigidos.

Para atingir tal objetivo, foi utilizada uma abordagem ao problema com a aplicação de modelos de regressão por meio de *Automated Machine Learning* (AutoML) obtidos com o uso da plataforma H2O, e auxílio da interface gráfica baseada em web chamada H2O Flow. Tais modelos baseiam-se no treinamento supervisionado embasado nos resultados obtidos pela solução de algoritmo de Matching proposto no trabalho [de Moraes et al. 2017]. Esse algoritmo de Matching se fundamenta em um método multicritério lógico-matemático que realiza a pontuação de provedores de nuvem a partir dos seus indicadores de desempenho. Assim, esse algoritmo resolve o problema de uma forma determinística sem a necessidade de outros artifícios. Entretanto, o tempo de resposta para a solução do algoritmo ainda pode ser melhorado, já que com grandes quantidades de dados ele se torna uma solução menos eficiente, por isso é proposta essa melhora com o uso

de modelos de *Machine Learning* (ML) que além de melhorar significativamente o tempo de resposta para a solução ainda consegue manter a mesma assertividade dos resultados.

2. Visão Geral da Abordagem Empregada

A abordagem é composta pela função de *Automated Machine Learning* da plataforma H2O em conjunto com a interface gráfica baseada em web H2O Flow. A razão de escolha da plataforma H2O é dada por sua documentação organizada e de fácil compreensão, em conjunto com a possibilidade de uso da interface gráfica baseada em web, essa que permite um bom fluxo de trabalho com visualização nítida de dados e gráficos. Com a plataforma é possível o treinamento, análise, e criação de modelos AutoML. Um modelo de ML é definido como um arquivo contendo as instruções para transformação de valor de entrada em valor de saída, conforme seu treinamento prévio no reconhecimento de certos tipos de padrões em dados, como por exemplo o modelo de regressão gerado e utilizado no trabalho, que parte da técnica de *Machine Learning* denominada *Gradient Boosting* (GBM). Assim no caso desse trabalho, o modelo é treinado para prever a pontuação de determinados provedores de nuvem a partir dos valores de seus indicadores de desempenho. A técnica GBM se baseia em árvores de decisão, e utiliza a função de perda ou *Loss Function* para indicar a qualidade dos coeficientes do modelo no ajuste de dados subjacentes, que podem ser definidos como o peso dado para cada categoria de indicadores (variáveis).

A abordagem empregada foi escolhida com a finalidade de agilizar o processo de obtenção dos resultados em comparação com a metodologia determinística e exata desenvolvida no trabalho de [de Moraes et al. 2017] e providenciar um ambiente mais simples para importação de base de dados e exportação dos resultados de predições. Na abordagem empregada, para oferecer uma maior riqueza de dados destinada ao treinamento de modelos AutoML, é usada uma base de dados de indicadores de provedores de nuvem fictícios (para o treinamento), gerada a partir de um algoritmo escrito em JavaScript. Esse algoritmo, a partir da base de indicadores de provedores de nuvem reais usada na metodologia determinística de [de Moraes et al. 2017], gera a base de dados de treino com mais entradas - aumentando de 300 provedores de nuvem reais para 5000 provedores de nuvem fictícios - e maior diversidade de valores. No algoritmo é usado uma variação da função *Random* da biblioteca *Math* do JavaScript que retorna um número inteiro aleatório para um caso ou um número racional aleatório para outro caso, conforme os parâmetros utilizados, entre os os limites mínimos e máximos definidos para os casos. Os indicadores utilizados juntamente com seus valores limites, mínimo e máximo, respectivamente, são apresentados na Tabela 1. Nessa tabela podem ser vistos os valores limites de quantidade de RAM, quantidade de armazenamento, um coeficiente de potência de processamento de CPU, a porcentagem de disponibilidade média de um serviço de provedor de nuvem por ano, um coeficiente de segurança e privacidade estimado, e o custo médio em dólar de serviço de provedor de nuvem por hora. Para obter a saída da base de dados, também é necessário a execução do algoritmo de Matching sobre essa nova base de dados a fim de obter a coluna das pontuações (*outputs*) de cada provedor de nuvem. Assim, a base de dados gerada contém os valores de indicadores definidos de forma aleatória, entretanto respeitando a lógica e os valores limites mínimos e máximos definidos pela base original.

Tabela 1. Limite dos valores de indicadores

Indicador	Valor Mínimo	Valor Máximo
RAM (Gb)	1	64
Armazenamento (Gb)	5	200
CPU	2	10
Disponibilidade (%)	95,2	99,99
Segurança	1	5
Custo (U\$/h)	0	10

3. Resultados Obtidos

Para testar a abordagem empregada, foi gerada uma nova base de dados de provedores de nuvem fictícios com indicadores de desempenho, com a utilização do algoritmo gerador, destinada a verificação do tempo de execução do modelo em comparação com o algoritmo de Matching. Essa base de dados possui como entrada 5000 provedores de nuvem fictícios e o valor de seus indicadores, gerados aleatoriamente dentro dos limites mínimos e máximos estabelecidos pela base de dados original com valores coletados a respeito de provedores de nuvem reais. Os resultados obtidos demonstram que o algoritmo determinístico de Matching realizou a tarefa de pontuação/ranqueamento dos provedores de nuvem em 7945 milissegundos (ms). Enquanto isso, com o modelo de regressão utilizando a técnica de *Gradient Boosting*, o tempo de execução para a predição da pontuação foi de apenas 254 ms. Isso demonstra uma melhora de 96,8% no tempo de execução quando lidando com base de dados de volume elevado.

Em relação a precisão dos resultados utilizando a abordagem empregada, foi aproveitado a mesma base de dados do trabalho [de Moraes et al. 2017] que possui 300 provedores de nuvem reais, para a realização da predição de pontuação utilizando o modelo de regressão com o algoritmo GBM. Assim, são comparados os valores de pontuação obtidos pelo algoritmo de Matching com os valores de predição de pontuação obtidos com o modelo criado pela função AutoML. Os valores da diferença entre as pontuações obtidas pelos dois métodos e a acurácia do método de modelo AutoML em comparação com o algoritmo de Matching, são exibidos em porcentagem para cada provedor de nuvem. Então, é apresentado apenas uma parcela, por motivos de síntese, desses resultados de precisão obtidos na Tabela 2. Os resultados demonstram a eficácia do modelo AutoML em manter a assertividade dos resultados esperados com um alto nível de acurácia. Essa assertividade quando observada de forma geral, também consegue manter o mesmo alto nível de acurácia, sendo 99,78% o valor de acurácia média entre todos os provedores de nuvem reais da base de dados utilizada.

4. Considerações Finais

Este trabalho tem como objetivo a automatização e agilização do processo de seleção de provedores nuvem. No trabalho, foi discutido um método determinístico capaz de realizar o problema de seleção de provedores de nuvem, entretanto com o tempo de resposta para a obtenção dos resultados que poderia ser melhorado. Então, com o uso do aprendizado de máquina automatizado foi possível resolver o problema de forma mais rápida e conservando a assertividade dos resultados que um método determinístico pode oferecer.

Tabela 2. Precisão dos resultados obtidos

Provedor	Matching	Modelo	Diferença (%)	Acurácia (%)
01	0,9996	0,9980	0,16	99,84
02	0,8249	0,8242	0,08	99,92
03	0,7957	0,7965	-0,10	99,90
04	0,7913	0,7907	0,08	99,92
05	0,7582	0,7577	0,06	99,94
06	0,7081	0,7090	-0,13	99,87
07	0,6956	0,6969	-0,18	99,82
08	0,6664	0,6677	-0,21	99,79
09	0,6581	0,6569	0,18	99,82
10	0,6455	0,6449	0,09	99,91
11	0,6288	0,6301	-0,20	99,80
12	0,6248	0,6238	0,15	99,85
13	0,6031	0,6023	0,13	99,87
14	0,5915	0,5902	0,22	99,78
15	0,5583	0,5601	-0,32	99,68

A abordagem empregada foi composta pela função de aprendizagem de máquina automatizado da plataforma H2O em conjunto com a interface gráfica baseada em web H2O Flow. Com essa abordagem, foi possível o treinamento de diversos modelos de aprendizado de máquina que façam uso de diferentes algoritmos e técnicas de *Machine Learning*. Assim, com a plataforma H2O, foi possível moldar um modelo específico para a resolução do problema de forma eficiente, com o uso da função AutoML.

Os resultados obtidos demonstraram que para o problema em questão, a abordagem adotada neste trabalho, conseguiu ser significativamente mais rápida quando comparada com a metodologia determinística. E alcançou esse resultado conservando um alto nível de acurácia sobre as previsões de pontuações comparadas com as pontuações calculadas utilizando o algoritmo de Matching. Assim, foi provado a eficácia da abordagem proposta para o problema trabalhado.

Referências

- de Moraes, L. B., Fiorese, A., and Matos, F. (2017). A multi-criteria scoring method based on performance indicators for cloud computing provider selection. In *ICEIS (2)*, pages 588–599.
- Repschläger, J., Wind, S., Zarnekow, R., and Turowski, K. (2011). Developing a cloud provider selection model. *Enterprise modelling and information systems architectures (EMISA 2011)*.