

# Problemas de Otimização em Ambientes de Computação em Nuvem

Nesta aula estudaremos alguns problemas de alocação de recursos em sistemas de Computação em Nuvem procurando modelá-los sob um olhar de otimização combinatória. Nosso principal intuito é exercitar, por meio de problemas e modelos simples, a criação de modelos em ambientes computacionais de larga escala.

## 1. Maior Receita na Nuvem (BLP)

Neste problema temos um conjunto  $\{1...V\}$  de VMs, sendo que cada VM  $i$  possui um preço  $p_i$  e uma **demanda** de capacidade  $d_i$ . Temos também um conjunto de servidores  $\{1...M\}$ , com cada servidor  $j$  possuindo sua respectiva capacidade  $C_j$ . Para representar a alocação de uma VM  $i$  em um servidor  $j$  utilizamos uma **variável de decisão** booleana  $x_{ij}$  que assume 1 no caso da máquina virtual  $i$  estar alocada no servidor  $j$ , e 0 caso contrário. Assim, o que desejamos é a maximização do lucro

$$\text{maximizar } \sum_{i=1}^V \sum_{j=1}^M p_i x_{ij}$$

sujeito às seguintes restrições

$$\sum_{i=1}^V d_i x_{ij} \leq C_j, \text{ para todo servidor } j$$

$$\sum_{j=1}^M x_{ij} \leq 1, \text{ para toda VM } i$$

$$x_{ij} \in \{0, 1\}, \text{ para todo } i \text{ e } j$$

Este problema é um problema NP-difícil e equivale ao problema das múltiplas mochilas (0-1 *Multiple Knapsack*). Este problema é descrito e diversas formas de solucioná-lo são apresentadas no Capítulo 6 do livro de Martello e Toth [1].

## 2. Gerência de Energia sem preço (BLP)

Neste problema faremos gerenciamento de energia por meio do desligamento de servidores. Novamente, temos um conjunto  $\{1...V\}$  de VMs, sendo que cada VM  $i$  possui apenas a sua respectiva demanda de capacidade  $d_i$ . Temos também um conjunto de servidores  $\{1...M\}$ , com cada servidor  $j$  possuindo sua respectiva capacidade  $C_j$ . Um servidor pode ou não estar ligado, o que é modelado por meio da variável de decisão booleana  $y_j$ , com 1 representando o servidor ligado e 0 desligado. A alocação da uma VM  $i$  em um servidor  $j$  é novamente modelada pela variável de decisão booleana  $x_{ij}$  que assume 1 no caso da máquina virtual  $i$  estar alocada no servidor  $j$ , e 0 caso contrário. Assim, o que desejamos é minimizar o número de servidores ativos.

$$\text{minimizar } \sum_{j=1}^M y_j$$

sujeito às seguintes restrições

$$\sum_{i=1}^V d_i x_{ij} \leq y_j C_j, \text{ para cada servidor } j$$

$$\sum_{j=1}^M x_{ij} = 1, \text{ para cada VM } i$$

$$x_{ij} \in \{0, 1\}, \text{ para todo } i \text{ e } j$$

$$y_j \in \{0, 1\}, \text{ para todo } j$$

Este problema é um problema NP-difícil e equivale ao problema conhecido como Bin-packing. Este problema é descrito e diversas formas de solucioná-lo são apresentadas no Capítulo 8 em [1].

### 3. Maximizando a Lucro (BLP)

Podemos modificar este problema adicionando preço. Para tanto, basta que adicionemos a variável do preço  $p_i$  de cada VM  $i$  e um custo energético de cada servidor  $w_j$ . Assim, desejamos otimizar a seguinte função objetivo

$$\text{maximizar } \left( \sum_{i=1}^V \sum_{j=1}^M p_i x_{ij} - \sum_{j=1}^M w_j y_j \right)$$

sujeita às seguintes restrições

$$\sum_{i=1}^V d_i x_{ij} \leq y_j C_j, \text{ para cada servidor } j$$

$$\sum_{j=1}^M x_{ij} \leq 1, \text{ para cada VM } i$$

$$x_{ij} \in \{0, 1\}, \text{ para todo } i \text{ e } j$$

$$y_j \in \{0, 1\}, \text{ para todo } j$$

### 4. Balanceamento de carga sem preço (BLP)

O objetivo neste problema é equalizar a carga entre os servidores existentes na Nuvem. Assim temos, novamente, um conjunto  $\{1 \dots V\}$  de VMs com suas respectivas demandas de capacidade  $d_i$  e temos também um conjunto de servidores  $\{1 \dots M\}$  com suas respectivas capacidades  $C_j$ . Como nos anteriores, a alocação da uma VM  $i$  em um servidor  $j$  é novamente

modelada pela variável de decisão booleana  $x_{ij}$ , que assume 1 no caso da VM  $i$  estar alocada no servidor  $j$ , e 0 caso contrário. Para este problema de seja-se

$$\text{minimizar } \max_{j=1 \dots M} \left( \sum_{i=1}^V d_i x_{ij} \right)$$

respeitando as seguintes restrições

$$\sum_{i=1}^V d_i x_{ij} \leq C_j, \text{ para cada servidor } j$$

$$\sum_{j=1}^M x_{ij} = 1, \text{ para cada VM } i$$

$$x_{ij} \in \{0, 1\}, \text{ para todo } i \text{ e } j$$

Este problema é **parecido** com o problema de partição de um conjunto de inteiros em K subconjuntos disjuntos, tal que as somas dos números em cada subconjunto sejam as mais próximas possíveis. Contudo, o problema difere no fato de que a soma dos inteiros alocados em cada subconjunto não pode ultrapassar um determinado valor, coisa que não ocorre no problema da partição de conjuntos. Uma discussão sobre o problema da partição de conjuntos pode ser encontrada em [2].

## 5. Proteção de Servidores (LP ou NLP)

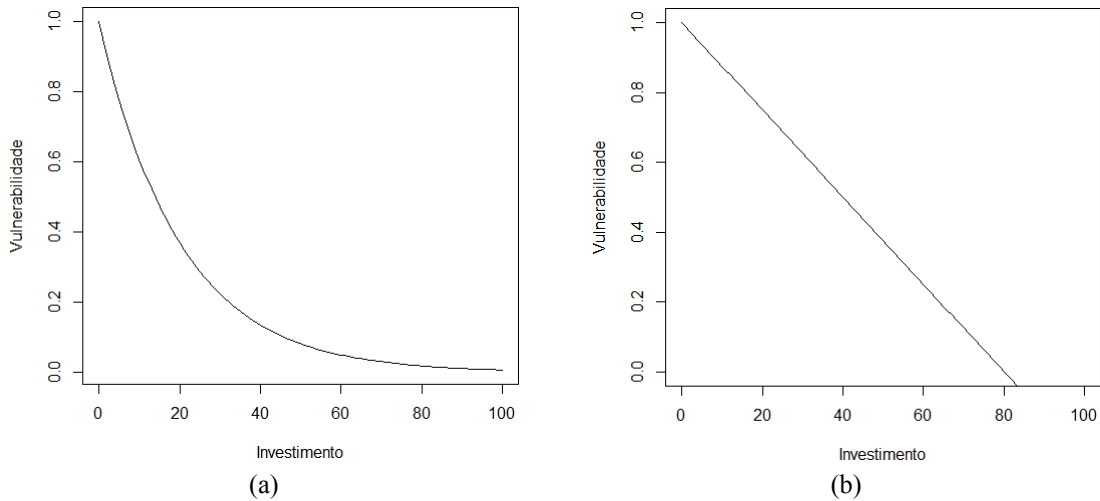
Neste problema introduzimos o conceito de risco. O risco é uma medida da importância de um sistema (ou um de seus componentes) e do quanto este sistema é suscetível a falhas. Assim, todo sistema pode ser visto como tendo uma vulnerabilidade, a qual é medida entre 0 e 1, e uma consequência, valor maior que zero, que indica qual o impacto da perda daquele sistema (ou componente) para seu administrador. Modelamos o risco de um sistema por meio da equação  $\text{risco} = \text{vulnerabilidade} \times \text{consequência}$ .

Para um sistema formado por **diversos componentes**, temos que o risco do sistema dependerá do risco individual de cada um dos seus componentes ( $r_i$ ). Considerando a existência de  $C$  componentes e que as falhas de cada componente são independentes e não afetam umas às outras temos que o risco do sistema é dado por

$$\sum_{i=1}^C r_i = \sum_{i=1}^C c_i v_i$$

Contudo, a vulnerabilidade de cada componente pode ser diminuída por meio do investimento na proteção daquele componente. Assim, a vulnerabilidade de um componente é dada pela função  $v_i(I_i)$ , com  $I_i$  correspondendo ao investimento feito no componente  $i$ . Esta função é decrescente, porém o formato da curva de decrescimento depende de cada componente. Uma forma corriqueira de descrever esta curva é por meio de uma **função exponencial** da

forma  $v_i(I_i) = e^{-\alpha I_i}$  como mostrada na Figura 1(a). Esta função é interessante porque reflete o aspecto dos **retornos decrescentes**, i.e., o retorno de investimento inicialmente é alto, mas decresce a medida que investimos mais. Outra função que pode ser utilizada é a **função linear** do tipo  $v_i(I_i) = 1 - \frac{I_i}{maxI_i}$  como mostrada na Figura 1(b). Embora a função linear não modele bem a vulnerabilidade de componentes reais, seu estudo pode ser interessante já que: a) permite uma solução simples e elegante para o problema que veremos a seguir; e b) é possível modelar partes de uma função qualquer por meio de uma função linear.



**Figura 1. Exemplo de funções de vulnerabilidade (a) Exponencial e (b) Linear.**

No contexto da Computação em Nuvem, podemos aplicar este modelo para decidir como distribuir os investimentos em um **conjunto de servidores**  $\{1...M\}$  de modo a minimizar **o risco**, mas sem que o total dos investimentos **ultrapassem um orçamento  $O$  dado**. Assim, devemos escolher qual o valor de investimento  $I_j$  deve ser destinado para a proteção de cada servidor  $j$  de acordo com a **consequência do servidor** ( $c_j$ ) e da sua **função de vulnerabilidade**  $v_j(I_j)$ . A consequência do servidor pode ser medida em termos de, por exemplo, o número de máquinas virtuais existentes no servidor, o custo para consertá-lo, a perda financeira caso ele falhe etc. Pode-se ainda usar qualquer combinação destes fatores, desde que  $c_j \geq 0$ . Já para a vulnerabilidade usaremos a função linear, assim, cada servidor possuirá seu próprio valor  $maxI_j$ , de forma que  $v_j(maxI_j) = 0$ .

Considerando estas variáveis, e que a variável de decisão são os valores de investimento  $I_j$  em cada servidor, nosso problema é

$$\text{minimizar } \sum_{j=1}^M c_j v_j(I_j)$$

respeitando a seguinte restrição

$$\sum_{j=1}^M I_j \leq O$$

Como utilizamos uma **função linear**, existe uma **solução gananciosa** para este problema que consiste em investir nos servidores com base no retorno de investimento, o qual é dado pelo índice  $\frac{c_j}{maxI_j}$ . Assim, basta ordenar os servidores com base nesta fração do maior para o menor retorno de investimento e selecionarmos os servidores com maior índice para investir, aplicando a estes servidores um investimento igual ao mínimo entre  $maxI_j$  e o restante do orçamento. Assim, uma vez selecionado um servidor para alocação, iremos nos esforçar para zerar a seu risco. Detalhes sobre este problema aplicado a outro contexto e a demonstração de que esta solução leva ao ótimo podem ser encontrados em [3].

A solução do problema **não linear**, i.e., usando a equação  $v_i(I_i) = e^{-\alpha I_i}$ , é obtida por meio de relaxação lagrangiana e pode ser encontrado em [3].

## 6. Alocação com risco mínimo (BLP)

Podemos introduzir no problema da alocação de máquinas virtuais a ideia de risco de modo que a alocação seja feita para obter o menor risco. Antes de introduzir este problema, introduziremos outro importante problema que utilizaremos para resolver o problema de alocação com risco mínimo.

### Fluxo de Custo Mínimo (LP)

O problema de fluxo de custo mínimo é importante por ter aplicações em diversos contextos da computação e engenharias, principalmente em redes de computadores. Neste problema temos um grafo  $G = (V, E)$  e dois vértices específicos  $s, t \in V$  que serão a origem e destino, respectivamente, do envio de um fluxo de tamanho  $d$ . Esta demanda deverá ser enviada através das arestas dos grafo de modo que, para cada enlace  $(i, j) \in E$ , teremos uma variável  $f_{ij} \geq 0$  que mede o quanto do fluxo atravessa o enlace, uma capacidade do enlace  $c_{ij}$  e um custo  $a_{ij}$  do enlace. Assim, devemos escolher quais enlaces utilizar, de modo que tenhamos o menor custo, sem que o fluxo enviado por meio de uma aresta ultrapasse a capacidade dela.

Assim temos que

$$\text{minimizar } \sum_{(i,j) \in E} a_{ij} f_{ij}$$

respeitando as seguintes restrições

$$\sum_{j \in V} f_{ji} - \sum_{j \in V} f_{ij} = -d, \text{ para } i = s$$

$$\sum_{j \in V} f_{ji} - \sum_{j \in V} f_{ij} = 0, \text{ para } i \neq s, t$$

$$\sum_{j \in V} f_{ji} - \sum_{j \in V} f_{ij} = d, \text{ para } i = t$$

$$0 \leq f_{ji} \leq c_{ij} \text{ para todo } (i, j) \in E$$

Este problema é conhecido por ter uma solução polinomial e para resolvê-lo existem diversos algoritmos. Mais detalhes sobre este problema e suas soluções podem ser encontrados em [4].

■

Retornemos ao problema de alocação com risco mínimo. Considere um ambiente de Computação em Nuvem com  $S = \{1 \dots M\}$  servidores, sendo que cada um possui sua capacidade  $C_j$  e probabilidade de falha  $p_j$ . Diferentemente dos problemas anteriores, as máquinas virtuais  $VM = \{1 \dots V\}$  são consideradas todas iguais, não havendo diferença de demanda, contudo cada VM tem uma consequência de perda  $w_i$ .

A variável de decisão  $x_{ij}$  indica que a VM  $i$  está alocada no servidor  $j$ . Introduzimos neste problema um parâmetro  $A_{ij}$ , que indica a afinidade de uma VM a um servidor. Assim, se a VM  $i$  pode ser alocada no servidor  $j$ , então  $A_{ij} = 1$ , caso contrário  $A_{ij} = 0$ . Note que esta variável permite a modelagem de situações onde uma determinada VM só pode ser alocada em determinados servidores devido a restrições como tipo do sistema operacional, arquitetura do processador, localização geográfica etc.

O problema, portanto, é alocar as VMs minimizando o risco na infraestrutura de nuvem. De modo formal queremos

$$\text{minimizar } \sum_{j=1}^M p_j \sum_{i=1}^V w_i x_{ij}$$

respeitando as seguintes restrições

$$x_{ij} \leq A_{ij}, \text{ para todo } i \text{ e } j$$

$$\sum_{j=1}^M x_{ij} = 1, \text{ para cada VM } i$$

$$\sum_{i=1}^V x_{ij} \leq C_j, \text{ para cada servidor } j$$

$$x_{ij} \in \{0, 1\}, \text{ para todo } i \text{ e } j$$

Este problema pode ser resolvido por meio de sua **redução** ao problema de fluxo de custo mínimo. Para tanto basta criar um problema de fluxo com uma demanda  $d$  igual ao número de VMs a ser alocadas e um grafo  $G = (V, E)$ , onde  $V = \{s\} \cup \{t\} \cup \{VM\} \cup \{S\}$  e  $E$  será construído da seguinte forma:

- a) Haverá um enlace partindo de  $s$  para todo vértice em  $i \in \{VM\}$ , os quais possuirão  $a_{si} = 0$  e  $c_{si} = 1$ ;

- b) Haverá um enlace partindo de cada vértice  $j \in \{S\}$  para o vértice  $t$ , os quais possuirão  $a_{jt} = 0$  e  $c_{jt} = C_j$ ;
- c) Caso  $A_{ij} = 1$ , então haverá uma aresta do vértice  $i \in \{VM\}$  ao vértice  $j \in \{S\}$ , a qual possuirá  $a_{ij} = p_j w_i$  e  $c_{ij} = 1$ . Caso  $A_{ij} = 0$ , nenhuma aresta é criada entre o vértice  $i \in \{VM\}$  ao vértice  $j \in \{S\}$ .

Como se pode notar, esta redução leva qualquer instância do problema de alocação com risco mínimo em uma instância do problema de fluxo de custo mínimo, o qual pode ser resolvido em tempo polinomial. Note que problemas de fluxo de custo mínimo podem ter solução fracionária ( $f_{ij} \in R$ ), contudo há um teorema que mostra que a solução será sempre inteira ( $f_{ij} \in Z$ ) para esta redução. Este problema, a redução para fluxo de custo mínimo e o teorema citado são apresentadas em [5] juntamente com avaliações.

## 7. Referências

- [1] Martello, S. e Toth, P. *Knapsack Problems: Algorithms and Computer Implementations*, Wiley & Sons, 1990, Disponível em: <http://www.or.deis.unibo.it/knapsack.html>
- [2] Korf, R. E. *Multi-Way Number Partitioning*, 21<sup>st</sup> International Joint Conference on Artificial Intelligence, 2009.
- [3] Lewis, T. G. *Network Science: Theory and Applications*, Wiley, 2009.
- [4] Jungnickel, D. *Graphs, Networks, and Algorithms*, Springer, 3<sup>a</sup> Edição, 2008.
- [5] Palhares, A. V. A. *Probabilistic Risk Assessment in Clouds: Models and Algorithms*, Dissertação de Mestrado, CIn/UFPE, 2012.