

DOI: 10.7652/xjtuxb201710022

一种低成本的云资源提供算法

陈俊杰, 周晖, 王伟
(南通大学电子信息学院, 226019, 江苏南通)

摘要: 针对云资源提供成本较高的问题,结合预留计划和按需计划,提出了一个两阶段的云资源提供算法,以降低服务提供商的运营成本。在预留阶段,根据历史数据估计工作负载需求的分布,将长期的资源预留问题规划为两阶段随机规划问题,并转化为确定性的整数规划问题进行求解;在按需阶段,采用基于卡尔曼滤波的工作负载预测算法预测工作负载需求,并且将按需资源提供问题规划为整数规划问题进行求解。仿真结果表明,所提出的云资源提供算法节省了超过 25% 的运营成本,同时保证了较低的服务等级协议违约率。

关键词: 云资源提供;资源预留;随机规划;卡尔曼滤波

中图分类号: TP312 **文献标志码:** A **文章编号:** 0253-987X(2017)10-0135-07

A Provision Algorithm for Cloud Resources with Cost Optimization

CHEN Junjie, ZHOU Hui, WANG Wei
(School of Electronics and Information, Nantong University, Nantong, Jiangsu 226019, China)

Abstract: A two-phase algorithm is proposed to reduce the operational cost for service providers in cloud resource provisioning problems. The distribution of workload demands is estimated based on historical data in the reservation phase, the long-term resource reservation problem is formulated as a two-stage stochastic integer programming problem and then transformed into a deterministic integer programming problem for solution. The workload prediction algorithm based on Kalman filtering is used to predict the workload demand in the on-demand phase, and then the on-demand provisioning problem is formulated as an integer programming problem for solution. Simulation results show that the proposed algorithm significantly reduces the operational cost while the service level agreement is guaranteed.

Keywords: cloud resource provisioning; resource reservation; stochastic programming; Kalman filtering

云计算是目前主流的信息技术发展趋势之一,其中基础设施即服务(IaaS)是应用最广泛的云计算服务模式。IaaS 通过虚拟化技术将硬件资源抽象成计算资源池,并且通过英特网提供给云消费者使用。云计算允许云消费者以按使用付费的方式租用资源,云消费者仅仅需要为它实际使用的资源付费。

云提供商通常向云消费者提供两种资源订购计划,即短期的按需计划和长期的预留计划。按需计划允许服务提供商根据实际需求动态获取资源,并且按使用付费。对于预留计划,服务提供商需要提前支付预付费用,在预留期间以更便宜的使用成本使用预留资源。通过使用预留计划,云消费者可以

节省运营成本。如果长期预留的资源超过实际需求,部分预留的资源得不到充分使用,会造成预留成本的浪费。如果预留的资源不能完全满足实际需求,需要按需分配额外的资源,会产生更高的按需资源使用成本。资源提供问题可以分为 2 个子问题:①在长期规划周期,预留多少资源,以实现预留成本和按需成本的权衡;②在短期规划周期,按需分配多少资源,以满足实际需求。

虚拟化是云计算的核心技术,重点研究虚拟机整合问题,通过虚拟机的实时迁移,在满足 QoS 需求的条件下,减少物理服务器的使用数量,从而降低能耗成本。Hermenier 等人提出了基于约束规划的动态整合机制^[1];李强等人将虚拟机放置问题描述为多目标优化问题,在保证多个应用的服务级目标的情况下,使得物理结点的使用数量和虚拟机迁移次数最小,并且提出了虚拟机放置多目标优化遗传算法^[2],通过 NSGA-II 遗传算法来求解虚拟机放置问题;Farahnakian 等人设计了一个分布式的系统架构来执行虚拟机的动态整合,并且提出了基于蚁群系统的虚拟机整合方法^[3];Tao 等人在虚拟机的动态迁移问题中,不仅考虑能耗成本和迁移成本,还考虑通信成本,提出了基于二进制图匹配的桶编码学习算法^[4],通过桶编码学习来寻找最优解,并使用二进制图匹配来评估候选解。

不同于上述以云提供商为中心的研究,本文侧重于以服务提供商为中心的资源提供问题。Calheiros 等人通过排队系统模型分析服务性能,并根据工作负载需求自适应提供资源^[5]。有许多方法可以用于预测工作负载需求,例如神经网络方法^[6]、ARIMA 模型^[7]等。Kingfisher 系统是一个成本感知的弹性资源提供系统^[8],可在满足服务需求的同时,最小化云租户的部署成本。Liu 等人提出了基于强化学习的激进的资源提供策略^[9],鼓励决策引擎在工作负载增加时大幅度地增加资源分配,从而保证高水平的 QoS。然而,上述研究仅仅考虑按需计划,没有考虑预留计划。Hwang 等人提出了一个两阶段的资源提供算法^[10],在第一阶段,确定最佳的资源预留方案,在第二阶段,根据预测的资源需求自适应订购按需资源。阚运奇等人为降低消费者租借云计算系统资源的开销,结合预留计划和按需计划,提出了成本约束的内存预留随机整数线性规划模型及方法^[11]。

本文针对云资源提供问题,结合预留计划和按需计划,提出了一个两阶段的云资源提供算法,旨在

保证服务等级协议的条件下,最小化服务提供商总的运营成本。在预留阶段,根据历史数据估计工作负载需求的分布,将长期的资源预留问题规划为两阶段随机规划问题,并转化为确定性的整数规划问题进行求解。在按需阶段,采用基于卡尔曼滤波的工作负载预测算法预测工作负载需求,并且将按需资源提供问题规划为整数规划问题进行求解。

1 云计算资源预留问题

1.1 云计算环境

针对特定的服务,云提供商提供了多种不同类型的虚拟机,假设 $V = \{V_1, V_2, \dots, V_N\}$ 表示虚拟机类型的集合, N 为云提供商所提供的虚拟机类型的总数,不同类型的虚拟机具有不同的硬件规格和服务容量。假设一个 V_i 类型的虚拟机的资源容量为 $R_i = [r_{i1}, r_{i2}, \dots, r_{iM}]$, M 为云提供商所提供的资源类型的总数,这些资源可以是 CPU、内存和网络带宽等。假设一个 V_i 类型的虚拟机的服务容量为 C_i ,是指在保证服务质量的前提下,一个 V_i 类型的虚拟机所能支持的最大的并发用户数或者服务请求到达速率。

假设一个 V_i 类型的虚拟机具有 N_i 个虚拟 CPU,服务请求到达过程为泊松过程,平均到达速率为 λ_i ,服务时间服从一般分布,平均服务速率为 μ_i 。因此,一个 V_i 类型的虚拟机可以建模为一个 $M/G/N_i$ 排队系统,服务请求的平均等待时间为

$$\bar{t}_i \approx \frac{p_{\text{busy},i}}{1 - \rho_i} \frac{1 + C_{v,i}^2}{2} \frac{1}{N_i \mu_i} \quad (1)$$

式中: $\rho_i = \lambda_i / (N_i \mu_i)$ 为服务强度; $C_{v,i}^2$ 为服务时间的平方变异系数; $p_{\text{busy},i}$ 为虚拟机繁忙的概率,其计算公式如下

$$p_{\text{busy},i} = \frac{(N_i \rho'_i)^{N_i}}{N_i! (1 - \rho_i)} \left[\sum_{k=0}^{N_i-1} \frac{(N_i \rho_i)^k}{k!} + \frac{(N_i \rho_i)^{N_i}}{N_i! (1 - \rho_i)} \right]^{-1} \quad (2)$$

其中 $\rho'_i = \lambda_i / \mu_i$ 。假设平均等待时间所允许的最大值为 $\bar{t}_{\text{imax}}$,根据式(1)可以确定服务请求到达速率所允许的最大值 λ_{imax} 使得 $\bar{t}_i \leq \bar{t}_{\text{imax}}$,即确定一个 V_i 类型的虚拟机的服务容量 C_i 。

云提供商提供了 2 种定价模式,按需实例和预留实例,按需实例适用于短期规划,预留实例适用于长期规划。假设短期规划的周期为 T_s ,长期规划的周期为 T_L , $T_s \ll T_L$ 。假设一个 V_i 类型的预留实例在 T_L 周期内的预留成本为 P_i^R ,归一化得到 T_s 周期内的预留成本为 p_i^R ,在 T_s 周期内的使用成本为

p_i^r ; 一个 V_i 类型的按需实例在 T_s 周期内的使用成本为 p_i^o , 通常假设 $p_i^o > p_i^r + p_i^r$ 。

1.2 基于随机规划的云计算资源预留问题

一个长期规划周期 T_L 包含 $T = T_L/T_s$ 个短期规划周期 T_s , 假设在第 t ($1 \leq t \leq T$) 个短期规划周期, 服务提供商的工作负载需求(平均服务请求到达速率)为 d_t 。令 $\mathbf{R} = [n_1, \dots, n_N]$ 表示长期规划周期的虚拟机预留配置, 其中 n_i 为预留的 V_i 类型的虚拟机的数量, 预留的总的服务容量为 $\sum n_i C_i$ 。在整个长期规划周期, 预留的虚拟机的总的预留成本为 $\sum n_i P_i^R$, 总的使用成本为 $\sum n_i p_i^r T$ 。在第 t 个短期规划周期, 当工作负载需求不超过预留的总的服务容量时, 不需要按需分配额外的虚拟机, 当工作负载需求超过预留的总的服务容量时, 需要按需分配额外的虚拟机, 按需分配的虚拟机的总的使用成本为

$$U(\mathbf{R}, d_t) = \min_{x_i \in \mathbb{N}_0} \sum_{i=1}^N x_i p_i^o$$

$$\text{s. t.} \quad \sum_{i=1}^N x_i C_i + \sum_{i=1}^N n_i C_i \geq d_t \quad (3)$$

式中: x_i 表示按需分配的 V_i 类型的虚拟机的数量。上述问题就是短期的资源分配问题, 即给定虚拟机预留配置 $\mathbf{R}$ 和工作负载需求 d_t , 按需分配额外的虚拟机, 在满足工作负载需求的前提下, 最小化按需分配的虚拟机的总的使用成本。

基于资源预留的云计算资源提供问题可以描述为

$$f_1(\mathbf{R}) = \min_{n_i \in \mathbb{N}_0} \left\{ \sum_{i=1}^N n_i p_i^R + \sum_{i=1}^N n_i p_i^r T + \sum_{t=1}^T U(\mathbf{R}, d_t) \right\} \quad (4)$$

式中: $\mathbf{R}$ 为决策变量, 即预留的虚拟机的数量; 目标函数 f_1 为长期规划周期中预留的虚拟机和按需分配的虚拟机的总成本。上述资源提供问题依赖于长期规划周期中的工作负载需求, 然而这些信息并不是事先已知的。假设在长期规划周期中, 工作负载需求的概率分布为 $p(D_k)$, $k=1, 2, \dots, K$, D_k ($D_1 < D_2 < \dots < D_K$) 为工作负载需求所有可能的取值, 根据工作负载需求的历史数据, 可以得到 $p(D_k)$ 的近似估计。因此, 上述资源提供问题可以描述为

$$f_2(\mathbf{R}) = \min_{n_i \in \mathbb{N}_0} \left\{ \sum_{i=1}^N n_i p_i^R + \sum_{i=1}^N n_i p_i^r T + \sum_{k=1}^K p(D_k) U(\mathbf{R}, D_k) \right\} \quad (5)$$

式中: 目标函数 f_2 为每个短期规划周期的平均运营成本。该问题是一个两阶段随机整数规划问题。第一阶段对应于长期的资源预留规划, 在长期规划周期开始之前, 根据工作负载需求的概率分布, 确定预留的虚拟机的类型和数量。第二阶段对应于短期的资源分配规划, 在短期规划周期中, 需要根据长期规划周期的资源预留配置和当前的工作负载需求, 确定需要按需分配的虚拟机的类型和数量。

上述基于两阶段随机规划的云计算资源提供问题可以转化为

$$f_3(\mathbf{R}) = \min_{n_i, x_{ki} \in \mathbb{N}_0} \left\{ \sum_{i=1}^N n_i p_i^R + \sum_{i=1}^N n_i p_i^r T + \sum_{k=1}^K \left[p(D_k) \sum_{i=1}^N x_{ki} p_i^o \right] \right\}$$

$$\text{s. t.} \quad \sum_{i=1}^N n_i C_i + \sum_{i=1}^N x_{ki} C_i \geq D_k, \quad k = 1, 2, \dots, K \quad (6)$$

该问题是一个确定性的整数线性规划问题, 称之为两阶段随机规划问题的确定性等价问题, 可以通过传统的优化问题求解软件求解。

2 云计算资源的按需分配

假设最优的资源预留方案为 $\mathbf{R}^* = [n_1^*, \dots, n_N^*]$, 预留的总的服务容量为 $\sum n_i^* C_i$ 。在第 t 个短期规划周期, 工作负载需求为 d_t , 若 $d_t > \sum n_i^* C_i$, 则预留的总的服务容量不足以满足工作负载需求, 需要按需分配额外的虚拟机。短期的资源规划问题可以表示为

$$\min_{x_i \in \mathbb{N}_0} \sum_{i=1}^N x_i p_i^o$$

$$\text{s. t.} \quad \sum_{i=1}^N x_i C_i + \sum_{i=1}^N n_i^* C_i \geq d_t \quad (7)$$

上述问题是一个整数线性规划问题, 可以转化为一个无界背包问题, 使用启发式算法或者动态规划方法进行求解。

短期的资源规划问题依赖于下一个短期规划周期的工作负载需求, 然而由于服务请求模式的随机性, 无法预知下一个短期规划周期的工作负载需求。本文提出了一个基于卡尔曼滤波的工作负载预测算法。

先前的研究^[7]表明, 工作负载序列往往呈现很强的自相关性, 因此使用 ARIMA(p, d, q) 模型对工作负载序列进行建模。根据 Box-Jenkins 方法^[12],

工作负载序列 d_t 必须转化为平稳时间序列,也就是说, d_t 的均值和方差均为常数,与时间 t 无关, d_t 与 $d_{t+\tau}$ 的自协方差仅仅取决于时间延迟 τ ,与时间起点 t 无关。通过差分运算对原始的工作负载序列进行平稳化处理,差分运算的次数即为 ARIMA(p, d, q) 模型的参数 d 。通过分析工作负载历史数据的自相关函数和偏自相关函数确定模型的阶数,即 ARIMA(p, d, q) 模型的参数 p 和 q 。若工作负载序列为 p 阶自回归过程,其偏自相关函数在 $\tau > p$ 时下降至显著水平以下。若工作负载序列为 q 阶移动平均过程,其自相关函数在 $\tau > q$ 时下降至显著水平以下。

工作负载序列 d_t 的 ARIMA 模型为

$$\bar{d}_t = \phi_1 \bar{d}_{t-1} + \phi_2 \bar{d}_{t-2} + \cdots + \phi_p \bar{d}_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \cdots + \theta_q \epsilon_{t-q} \quad (8)$$

式中: $\bar{d}_t = \nabla^d d_t$; ϵ_t 服从均值为 0、方差为 σ^2 的高斯分布; $\Phi = [\phi_1, \cdots, \phi_p]$ 为自回归系数; $\Theta = [\theta_1, \cdots, \theta_q]$ 为移动平均系数。令 $r = \max(p, q+1)$, 上式可以重写为

$$\bar{d}_t = \phi_1 \bar{d}_{t-1} + \phi_2 \bar{d}_{t-2} + \cdots + \phi_r \bar{d}_{t-r} + \epsilon_t + \theta_1 \epsilon_{t-1} + \cdots + \theta_{r-1} \epsilon_{t-r+1} \quad (9)$$

式中: $i > p$ 时 $\phi_i = 0$; $i > q$ 时 $\theta_i = 0$ 。工作负载序列 d_t 的 ARIMA 模型的状态空间形式可以表示为

$$\left. \begin{aligned} \text{量测方程: } \bar{d}_t &= \mathbf{G}\mathbf{x}_t + W_t \\ \text{状态方程: } \mathbf{x}_t &= \mathbf{F}\mathbf{x}_{t-1} + \mathbf{V}_t \end{aligned} \right\} \quad (10)$$

式中: $\bar{d}_t$ 为量测变量; $\mathbf{x}_t$ 为 $r \times 1$ 维状态向量; $\mathbf{G}$ 为量测矩阵; $\mathbf{F}$ 为状态转移矩阵; 量测噪声 $W_t = 0$, 量测噪声的方差 $R = 0$; 过程噪声 $\mathbf{V}_t = [\epsilon_t, 0, \cdots, 0]^T$, 过程噪声的协方差矩阵 $\mathbf{Q} = \begin{bmatrix} \sigma^2 & \mathbf{0}_{1 \times (r-1)} \\ \mathbf{0}_{(r-1) \times 1} & \mathbf{0}_{(r-1) \times (r-1)} \end{bmatrix}$ 。

根据工作负载序列 d_t 的状态空间模型,可以得到卡尔曼滤波递推公式的预测方程组和更新方程组如下

$$\left. \begin{aligned} \mathbf{x}_{t/t-1} &= \mathbf{F}\mathbf{x}_{t-1/t-1} \\ \mathbf{P}_{t/t-1} &= \mathbf{F}\mathbf{P}_{t-1/t-1}\mathbf{F}^T + \mathbf{Q} \\ \bar{\mathbf{d}}_{t/t-1} &= \mathbf{G}\mathbf{x}_{t/t-1} \\ \mathbf{Z}_{t/t-1} &= \mathbf{G}\mathbf{P}_{t/t-1}\mathbf{G}^T \end{aligned} \right\} \quad (11)$$

$$\left. \begin{aligned} \mathbf{x}_{t/t} &= \mathbf{x}_{t/t-1} + \mathbf{H}_t(\bar{\mathbf{d}}_t - \mathbf{G}\mathbf{x}_{t/t-1}) \\ \mathbf{P}_{t/t} &= (\mathbf{I} - \mathbf{H}_t\mathbf{G})\mathbf{P}_{t/t-1} \\ \mathbf{H}_t &= \mathbf{P}_{t/t-1}\mathbf{G}^T(\mathbf{G}\mathbf{P}_{t/t-1}\mathbf{G}^T)^{-1} \end{aligned} \right\} \quad (12)$$

式中: $\mathbf{x}_{0/0}$ 、 $\mathbf{P}_{0/0}$ 为卡尔曼滤波的初值; $\mathbf{H}_t$ 为卡尔曼增益矩阵。基于卡尔曼滤波的工作负载序列 d_t 的一步预测方程为

$$d_t = - \sum_{j=1}^d \binom{d}{j} (-1)^j d_{t-j} + \mathbf{G}\mathbf{x}_t^{-1} \quad (13)$$

令 $\phi = \{\mathbf{x}_{0/0}, \mathbf{P}_{0/0}, \Phi, \Theta, \sigma^2\}$ 表示卡尔曼滤波中所有未知参数的集合,使用极大似然法进行参数估计。在正态假设条件下,量测数据序列 $D_n = \{\bar{d}_1, \bar{d}_2, \cdots, \bar{d}_n\}$ 的对数似然函数 $\ln L(D_n; \phi)$ 的计算式为

$$\ln L(D_n; \phi) = -\frac{1}{2} \sum_{t=1}^n \ln |\mathbf{G}\mathbf{P}_{t/t-1}\mathbf{G}^T| - \frac{1}{2} \sum_{t=1}^n (\bar{d}_t - \mathbf{G}\mathbf{x}_{t/t-1})^2 (\mathbf{G}\mathbf{P}_{t/t-1}\mathbf{G}^T)^{-1} \quad (14)$$

参数 ϕ 的极大似然估计为 $\hat{\phi} = \max_{\phi} \ln L(D_n; \phi)$ 。通常使用牛顿迭代法求解参数 ϕ 的极大似然估计,然而牛顿迭代法计算复杂,且容易收敛到局部最优解。这里采用 EM 算法求解参数 ϕ 的极大似然估计。令 $X_n = \{\mathbf{x}_0, \mathbf{x}_1, \cdots, \mathbf{x}_n\}$ 表示状态数据序列。在正态假设条件下,完整数据 $\{D_n, X_n\}$ 的对数似然函数为

$$\begin{aligned} \ln L(D_n, X_n; \phi) &= -\frac{1}{2} \ln |\mathbf{P}_{0/0}| - \frac{1}{2} (\mathbf{x}_0 - \mathbf{x}_{0/0})^T \mathbf{P}_{0/0}^{-1} (\mathbf{x}_0 - \mathbf{x}_{0/0}) - \frac{n}{2} \ln |\mathbf{Q}| - \\ &\quad \frac{1}{2} \sum_{t=1}^n (\mathbf{x}_t - \mathbf{F}\mathbf{x}_{t-1})^T \mathbf{Q}^{-1} (\mathbf{x}_t - \mathbf{F}\mathbf{x}_{t-1}) - \frac{n}{2} \ln \mathbf{R} - \frac{1}{2} \sum_{t=1}^n (\bar{d}_t - \mathbf{G}\mathbf{x}_t)^2 \mathbf{R}^{-1} \end{aligned} \quad (15)$$

式中: $\mathbf{R}$ 和 $\mathbf{Q}$ 的零对角线元素看成是趋向于 0 的无穷小量。EM 算法是一个迭代方法,每次迭代包含求期望(E)和最大化(M)两个步骤,通过不断地最大化完整数据似然函数的条件期望,得到基于不完整数据的参数的极大似然估计。在求期望步骤中,根据前一次迭代的参数估计 $\phi^{(j-1)}$,计算完整数据似然函数的条件期望

$$Q(\phi | \phi^{(j-1)}) = E\{\ln L(D_n, X_n; \phi) | D_n, \phi^{(j-1)}\} \quad (16)$$

对式(15)取条件期望,可以得到

$$\begin{aligned} Q(\phi | \phi^{(j-1)}) &= -\frac{1}{2} \ln |\mathbf{P}_{0/0}| - \frac{1}{2} \text{tr}\{\mathbf{P}_{0/0}^{-1} [\mathbf{P}_{0/n} + (\mathbf{x}_{0/n} - \mathbf{x}_{0/0})(\mathbf{x}_{0/n} - \mathbf{x}_{0/0})^T]\} - \frac{n}{2} \ln |\mathbf{Q}| - \\ &\quad \frac{1}{2} \text{tr}\{\mathbf{Q}^{-1} [\mathbf{S}_{11} - \mathbf{S}_{10}\mathbf{F}^T - \mathbf{F}\mathbf{S}_{10}^T + \mathbf{F}\mathbf{S}_{00}\mathbf{F}^T]\} - \frac{n}{2} \ln \mathbf{R} - \frac{1}{2} \text{tr}\{\mathbf{R}^{-1} \sum_{t=1}^n [(\bar{d}_t - \mathbf{G}\mathbf{x}_{t/n})^2 + \mathbf{G}\mathbf{P}_{t/n}\mathbf{G}^T]\} \end{aligned} \quad (17)$$

式中: $\mathbf{S}_{11} = \sum_{t=1}^n (\mathbf{x}_{t/n}\mathbf{x}_{t/n}^T + \mathbf{P}_{t/n})$; $\mathbf{S}_{10} = \sum_{t=1}^n (\mathbf{x}_{t/n}\mathbf{x}_{t-1/n}^T + \mathbf{P}_{t,t-1/n})$; $\mathbf{S}_{00} = \sum_{t=1}^n (\mathbf{x}_{t-1/n}\mathbf{x}_{t-1/n}^T + \mathbf{P}_{t-1/n})$ 。

使用卡尔曼滤波、平滑以及一阶延迟协方差平滑递推公式计算 $\mathbf{x}_{t/n}$ 、 $\mathbf{P}_{t/n}$ 和 $\mathbf{P}_{t,t-1/n}$ 。在最大化步骤中,选择参数 $\psi^{(j)}$,使得完整数据似然函数的条件期望 $Q(\psi|\psi^{(j-1)})$ 最大化。根据多元函数极值理论,令 $\partial Q(\psi|\psi^{(j-1)})/\partial \psi = 0$,可以得到卡尔曼滤波的参数估计为

$$\left. \begin{aligned} \phi_i^{(j)} &= (\mathbf{S}_{10} \mathbf{S}_{00}^{-1})_{1i}, i = 1, \cdots, p \\ \sigma^{2(j)} &= (n^{-1}(\mathbf{S}_{11} - \mathbf{S}_{10} \mathbf{F}^T - \mathbf{F} \mathbf{S}_{10}^T + \mathbf{F} \mathbf{S}_{00} \mathbf{F}^T))_{11} \\ \theta_i^{(j)} &= ((\sum_{t=1}^n \bar{d}_t \mathbf{x}_{t/n}^T) \mathbf{S}_{11}^{-1})_{i+1}, i = 1, \cdots, q \\ \mathbf{x}_{0/0}^{(j)} &= \mathbf{x}_{0/n}; \mathbf{P}_{0/0}^{(j)} = \mathbf{P}_{0/n} \end{aligned} \right\}$$

(18)

根据上述分析,基于 EM 算法的参数估计的迭代过程如下:

(1)选择参数 ψ 的初值 $\psi^{(0)} = \{\mathbf{x}_{0/0}^{(0)}, \mathbf{P}_{0/0}^{(0)}, \boldsymbol{\Phi}^{(0)}, \boldsymbol{\Theta}^{(0)}, \sigma^{2(0)}\}$;

(2)在求期望步骤中,给定 $\psi^{(j-1)}$,使用卡尔曼滤波、平滑以及一阶延迟协方差平滑递推公式计算 $\mathbf{x}_{t/n}$ 、 $\mathbf{P}_{t/n}$ 、 $\mathbf{P}_{t,t-1/n}$,并使用 $\mathbf{x}_{t/n}$ 、 $\mathbf{P}_{t/n}$ 、 $\mathbf{P}_{t,t-1/n}$ 计算 $\mathbf{S}_{11}$ 、 $\mathbf{S}_{10}$ 、 $\mathbf{S}_{00}$;

(3)在最大化步骤中,使用式(18)更新参数估计,得到 $\psi^{(j)}$;

(4)重复步骤(2)~(3)直至收敛。

在短期规划周期中,即使使用一个工作负载预测算法,仍然可能发生资源不足的情况,导致服务等级协议(SLA)违约。SLA 违约率定义为

$$P_{\text{SLA}} = \frac{T_u}{T}$$

(19)

式中: T_u 为资源不足的短期规划周期的数目。为了降低 SLA 违约率,需要修正工作负载序列的一步预测方程。在正态假设条件下, d_t 服从均值为 $-\sum_{j=1}^d \binom{d}{j} (-1)^j d_{t-j} + \mathbf{G} \mathbf{x}_{t/t-1}$ 、方差为 $\mathbf{G} \mathbf{P}_{t/t-1} \mathbf{G}^T$ 的正态分布。因此,工作负载序列 d_t 的一步预测方程修正为

$$d_t = -\sum_{j=1}^d \binom{d}{j} (-1)^j d_{t-j} + \mathbf{G} \mathbf{x}_{t/t-1} + \alpha \mathbf{G} \mathbf{P}_{t/t-1} \mathbf{G}^T, \quad \alpha > 0$$

(20)

式(20)表明, α 值越大,分配的资源越多,SLA 违约率越小。因此,需要选择合适的 α 值实现运营成本和 SLA 违约率之间的权衡。

3 仿真实验

实验所用的负载数据为某网站一个月时间内工

作负载需求的历史数据,如图 1 所示。根据工作负载需求的历史数据,可以得到工作负载需求的概率分布的近似估计,如图 2 所示。针对 Web 服务,云提供商 Amazon EC2 提供了 4 种虚拟机类型——Small (m1. small)、Medium (m1. medium)、Large (m1. large)、Extra Large (m1. xlarge),每种虚拟机类型的定价模型和服务容量^[10]如表 1 所示。

图 1 某网站一个月内工作负载需求的历史数据

图 2 图 1 工作负载需求的概率密度分布

表 1 每种虚拟机类型的定价模型和服务容量

V_i	$p_i^R /$	$p_i^T /$	$p_i^O /$	C_i / s^{-1}
	美元 $\cdot \text{h}^{-1}$	美元 $\cdot \text{h}^{-1}$	美元 $\cdot \text{h}^{-1}$	
Small	0.014	0.010	0.044	10
Medium	0.028	0.020	0.087	30
Large	0.056	0.042	0.175	65
Extra Large	0.113	0.083	0.350	100

3.1 资源预留方案对运营成本的影响

首先分析不同的虚拟机预留配置对运营成本的影响。式(5)的所有可行解都是可选的虚拟机预留配置。对于任意可行解 $\mathbf{R}$,如果存在另一个可行解 $\mathbf{R}'$, $\sum n'_i (p_i^R + p_i^T) \leq \sum n_i (p_i^R + p_i^T)$, $\sum n'_i C_i \geq \sum n_i C_i$, 则 $\mathbf{R}$ 一定不是式(5)的最优解,因此式(5)的最优解的候选集为 $\{\mathbf{R} \mid \forall \mathbf{R}', \sum n_i (p_i^R + p_i^T) \leq$

http://www.jdxb.cn

http://zkxb.xjtu.edu.cn

$\sum n'_i(p_i^R + p_i^S), \sum n_i C_i \geq \sum n'_i C_i \}$ 。研究不同的候选最优解下总的运营成本,结果如图 3 所示。从图 3 中可以看出,随着预留的总服务容量的增加,预留成本和预留实例的使用成本逐渐增大,按需实例的使用成本逐渐减小,在预留的总服务容量较小或者较大时总的运营成本均较高,这是因为在预留的总服务容量较小时,需要更多使用成本较高的按需实例,在预留的总服务容量较大时,部分预留实例得不到充分使用,造成运营成本的浪费。最佳的虚拟机预留配置为 $\{n_1=0, n_2=0, n_3=4, n_4=0\}$,此时预留的总服务容量 C_i 为 260 s^{-1} ,总运营成本为 5 694.2 美元。比较本文所提出的算法和文献[10]算法的性能,结果如表 2 所示。从表 2 可以看出,2 种算法均可获得最佳的虚拟机预留配置,节省了超过 25% 的运营成本,但是文献[10]算法的求解过程所消耗的时间更长,并且当最优解不在搜索范围内时不能获得最优的资源预留方案。




图 3 资源预留方案对运营成本的影响

表 2 2 种算法的性能比较

算法	R	运营成本/美元	消耗时间/s
本文	$[0,0,4,0]$	5 694.2	15.82
文献[10]	$[0,0,4,0]$	5 694.2	242.44

3.2 基于卡尔曼滤波的工作负载预测算法

接下来分析基于卡尔曼滤波的工作负载预测算法的性能。使用基于卡尔曼滤波的预测算法对每个短期规划周期的工作负载需求进行预测,将前 3 周数据作为训练数据,最后一周数据作为测试数据,预测结果如图 4 所示。从图 4 中可以看出,预测的工作负载需求非常接近实际的工作负载需求。采用归一化的平均相对误差 E_{MAP} 、均方根误差 E_{RMS} 和平均绝对误差 E_{MA} 3 个指标,比较本文所提出的预测算法和 ARIMA 模型、神经网络方法的预测精度。神

经网络方法采用后向传播神经网络,学习率设为 0.7,仅有一个隐层,输入层、隐层和输出层的神经元数分别为 6、4 和 1。ARIMA 模型自回归阶数为 2,移动平均阶数为 1。从表 3 可以看出,本文所提算法的预测精度优于其他 2 种算法。




图 4 预测结果

表 3 几种不同的预测算法预测精度的比较

预测算法	E_{MAP}	E_{RMS}	E_{MA}
卡尔曼滤波	0.187 0	48.400 2	38.525 7
ARIMA 模型	0.209 2	53.825 1	42.935 9
神经网络	0.204 5	54.606 9	42.888 9

为了降低 SLA 违约率,使用修正的工作负载预测公式(20)预测工作负载,分析参数 α 对 SLA 违约率和运营成本的影响,结果如图 5 所示。从图中可以看出,随着 α 值增大,SLA 违约率逐渐减小,而总的运营成本逐渐增大。在实际应用中,需要选择合适的 α 值,实现总的运营成本和 SLA 违约率之间的平衡。




图 5 SLA 违约率和运营成本随参数 α 的变化

4 结 语

本文提出了一个两阶段的云资源提供算法。在预留阶段,根据历史数据估计工作负载需求的分布,将长期的资源预留问题规划为两阶段随机规划问题,并转化为确定性的整数规划问题进行求解。在按需阶段,采用基于卡尔曼滤波的工作负载预测算

法预测工作负载需求,将按需资源提供问题规划为整数规划问题,并转化为背包问题进行求解。基于真实的工作负载数据及 Amazon EC2 的定价模型评估了所提出的云资源提供算法。仿真结果表明,所提出的长期资源预留算法能够获得近似最优的运营成本,所提出的按需资源提供算法能够在保证 SLA 的条件下有效降低运营成本。

参考文献:

- [1] HERMENIER F, LORCA X, MENAUD J M, et al. Entropy: a consolidation manager for clusters [C]//ACM SIGPLAN/SIGOPS International Conference on Virtual Execution Environments. New York, USA: ACM, 2009: 41-50.
- [2] 李强,郝沁汾,肖利民,等.云计算中虚拟机放置的自适应管理与多目标优化[J].计算机学报,2011,34(12):2253-2264.
LI Qiang, HAO Qinfen, XIAO Limin. Adaptive management and multi-objective optimization for virtual machine placement in cloud computing [J]. Chinese Journal of Computers, 2011, 34(12): 2253-2264.
- [3] FARAHNAKIAN F, ASHRAF A, PAHIKKA-LA T, et al. Using ant colony system to consolidate VMs for green cloud computing [J]. IEEE Transactions on Services Computing, 2015, 8(2): 187-198.
- [4] TAO F, LI C, LIAO T W, et al. BGM-BLA: a new algorithm for dynamic migration of virtual machines in cloud computing [J]. IEEE Transactions on Services Computing, 2016, 99: 910-925.
- [5] CALHEIROS R N, RANJAN R, BUYYA R. Virtual machine provisioning based on analytical performance and QoS in cloud computing environments [C]//International Conference on Parallel Processing. Piscataway, NJ, USA: IEEE, 2011: 295-304.
- [6] ISLAM S, KEUNG J, LEE K, et al. Empirical prediction models for adaptive resource provisioning in the cloud [J]. Future Generation Computer Systems, 2012, 28(1): 155-162.
- [7] CALHEIROS R N, MASOUMI E, RANJAN R, et al. Workload prediction using ARIMA model and its impact on cloud applications' QoS [J]. IEEE Transactions on Cloud Computing, 2015, 3(4): 449-458.
- [8] SHARMA U, SHENOY P, SAHU S, et al. A cost-aware elasticity provisioning system for the cloud [C]//International Conference on Distributed Computing Systems. Piscataway, NJ, USA: IEEE, 2011: 559-570.
- [9] LIU J, ZHANG Y, ZHOU Y, et al. Aggressive resource provisioning for ensuring QoS in virtualized environments [J]. IEEE Transactions on Cloud Computing, 2015, 3(2): 119-131.
- [10] HWANG R H, LEE C N, CHEN Y R, et al. Cost optimization of elasticity cloud resource subscription policy [J]. IEEE Transactions on Services Computing, 2014, 7(4): 561-574.
- [11] 阚运奇,刘宏伟,左德承,等.云计算系统虚拟机内存资源预留方法[J].国防科技大学学报,2016,38(5):45-51.
KAN Yunqi, LIU Hongwei, ZUO Decheng, et al. Memory resources reservation method for virtual machine in cloud computing system [J]. Journal of National University of Defense Technology, 2016, 38(5): 45-51.
- [12] BOX G E P, JENKINS G M, REINSEL G C. Time series analysis: forecasting and control [M]. 4th ed. Hoboken, NJ, USA: Wiley, 2008: 93-125.

[本刊相关文献链接]

- 何秀丽,任智源,史晨华,等.面向医疗大数据的云雾网络及其分布式计算方案.2016,50(10):71-77.[doi:10.7652/xjtuxb201610011]
- 边根庆,翟红,邵必林.一种采用云模型的同驻虚拟机侧通道攻击威胁度量方法.2016,50(4):21-27.[doi:10.7652/xjtuxb201604004]
- 李谦,伍卫国,曹莹方,等.面向能耗优化的云渲染系统任务调度策略.2016,50(2):1-6.[doi:10.7652/xjtuxb201602001]
- 周墨颂,朱正东,董小社,等.采用资源划分的云环境下 Hadoop 资源许可调度方法.2015,49(8):69-74.[doi:10.7652/xjtuxb201508012]
- 郑鹏飞,尤佳莉,王劲林,等.一种多租户云的内部网络共享策略.2014,48(8):54-59.[doi:10.7652/xjtuxb201408010]
- 马莉,唐善成,王静,等.云计算环境下的动态反馈作业调度算法.2014,48(7):77-82.[doi:10.7652/xjtuxb201407014]
- 熊金波,姚志强,马建峰,等.云计算环境中的组合文档模型及其访问控制方案.2014,48(2):25-31.[doi:10.7652/xjtuxb201402005]
- 庄威,桂小林,林建材,等.云环境下基于多属性层次分析的虚拟机部署与调度策略.2013,47(2):28-32.[doi:10.7652/xjtuxb201302005]
- 吾守尔·斯拉木,曹巨明.一种新的散乱点云尖锐特征提取方法.2012,46(12):1-5.[doi:10.7652/xjtuxb201212001]
- 李健,黄庆佳,刘一阳,等.云计算环境下的大规模图状数据处理任务调度算法.2012,46(12):116-122.[doi:10.7652/xjtuxb201212020]

(编辑 刘杨)