

基于大数据的专属私有云运营效率优化研究

Research on Optimization of Exclusive Cloud Operation Efficiency Based on Big Data

郭年庚,赵 帅,杨海明,许海峰,赵 涵(联通数字科技有限公司,北京 100032)

Guo Niangeng,Zhao Shuai,Yang Haiming,Xu Haifeng,Zhao Han(China Unicom Digital Technology Co.,Ltd.,Beijing 100032,China)

摘 要:

分析了专属私有云运营过程中,无法有效预判容量瓶颈以及云资源利用率难以精细化管理的痛点问题。使用回归分析和方差分析等大数据分析技术,选取某专属私有云平台运营数据,建立定量预测模型和资源利用率分析模型,得出运行天数与vCPU、内存和磁盘利用率关系,实现预测云资源容量出现瓶颈的时间,同时得出不同时间段对vCPU和内存利用率的波动影响程度,用以指导防止出现容量瓶颈和均衡资源利用率。

关键词:

云计算;专属私有云;资源优化;回归分析;方差分析

doi:10.12045/j.issn.1007-3043.2026.06.016

文章编号:1007-3043(2026)06-0087-06

中图分类号:TP391

文献标识码:A

开放科学(资源服务)标识码(OSID):



Abstract:

It analyzes the pain points of inability to effectively predict capacity bottlenecks and difficulty in refined management of cloud resource utilization in the operation process of exclusive private clouds. It uses big data analysis techniques such as regression analysis and variance analysis, selects operational data from a dedicated private cloud platform, establishes quantitative prediction models and resource utilization analysis models, and obtains the relationship between operating days and vCPU, memory, and disk utilization rates to predict the bottleneck time of cloud resource capacity. At the same time, the impact of different time periods on the fluctuation of vCPU and memory utilization rates is obtained to guide the prevention of capacity bottlenecks and balance resource utilization.

Keywords:

Cloud computing; Exclusive private cloud; Resource optimization; Regression analysis; Analysis of variance

引用格式:郭年庚,赵帅,杨海明,等. 基于大数据的专属私有云运营效率优化研究[J]. 邮电设计技术,2026(6):87-92.

0 引言

随着云计算的不断发展和技术的更新迭代,公有云已不能完全满足用户需求^[1],逐渐出现了针对不同业务场景的差异化云产品^[2],如行业云、通信云、调度云等^[3]。专属私有云是行业客户通过以租代建的方式,为满足用户特定业务、管理和安全需求的定制化专属云。

在专属私有云平台中,一般面临大量且复杂的用户任务,而任务处理效率会受到资源利用率的影响。云平台资源利用率主要包括内存资源利用率和CPU资源利用率等^[4],研究如何合理利用云资源对平台承载的系统顺畅运转具有重要意义^[5]。针对资源利用率较低的问题,通常进行被动和主动弹性伸缩^[6]。被动的方式是当系统的资源利用率达到定义的阈值时触发弹性伸缩操作,然而这种方式的时效性较差。主动的方式是建立某种预测模型,例如使用多目标优化^[7-9]、深度学习异常检测^[10]、任务调度算法^[11-13]、自适

收稿日期:2026-04-22

应算法^[14]、聚类分析^[15]等技术对历史数据进行提前预测,保证云资源的合理利用。本文通过引入大数据分析技术,对云平台的运营数据进行分析,实现对容量瓶颈的预测和资源利用率的优化,指导专属私有云用户提升云运营效率。

1 现状及存在的问题

在专属私有云运营工作中,经常面临以下2个方面的痛点问题。

a) 未能有效预判云资源容量瓶颈。由于上云业务系统的种类和重要程度各有不同,发展规模和速度也就不同,所以云资源的使用量变化情况也变得异常复杂,往往都是业务系统所用资源出现瓶颈时才会制定扩容计划、申请资金、资金批复、招投标、采购、实施,整个流程需要至少6个月的时间,极大影响了业务系统发展和服务体验。这种“粗放式”信息化管理和发展模式一直持续至今,用户迫切希望服务提供者能够提出有效的技术方案解决所面临的痛点问题。

b) 缺乏对云资源利用率的精细化管理。云平台建设完成后,通常会按照业务系统责任单位提出的资源申请进行开通,不会关注资源利用率分配是否均衡,造成资源的大量浪费,用户也迫切希望服务提供者能够提出解决该问题的技术方案,实现资源的精细化管理。

上述问题在信息化发展过程中一直困扰着专属私有云用户群体,同时也是制约用户数字化转型的关键问题,因而在专属私有云运营工作中,迫切需要引入大数据分析技术,以解决用户所面临的痛点问题,提升运营效率和用户体验。

2 研究方法

2.1 容量瓶颈预测方法

为了解决用户面临的云资源容量瓶颈无法预测的问题,使预算申报更加合理和及时,信息化管理更加精细化,引入大数据回归分析技术,建立定量预测模型预测容量瓶颈,提出扩容方案。解决云资源容量问题的关键点是研究运行天数对虚拟机(vCPU)、内存和硬盘利用率的影响,需要通过大数据分析技术对云平台收集的资源使用量数据进行分析,研究vCPU、内存和磁盘三要素与运行时间的关系,这比较适合采用回归分析方法。

回归分析旨在研究事物之间的数量关系(函数关

系),即找到回归方程,分析各因素对目标变量的影响程度,根据自变量预测因变量。按照自变量的数量可将回归分析划分为一元回归和多元回归,按照回归曲线的形态可将回归分析划分为线性回归和曲线回归。回归分析的本质就是找到最合适的回归方程来拟合业务各要素间的数量关系。评估回归分析模型质量的指标为判定系数 R^2 ,该指标表示回归线对数据的拟合程度,用来衡量回归方程对因变量 y 的变化的解释程度。

2.1.1 定量预测模型的评估指标

2.1.1.1 变差指标

使用总变量差SST、回归变差SSR和剩余变差SSE作为变差指标评估模型的拟合效果。总变量差SST计算公式如式(1)所示,表示真实值 y_i 与平均值 $\bar{y}$ 间的差的平方和,代表因变量的总体变异程度。回归变差SSR计算公式如式(2)所示,表示预测值 $\hat{y}_i$ 与平均值 $\bar{y}$ 的差的平方和,即预测值的均差平方和,代表模型中自变量对因变量变异的影响程度。剩余变差SSE计算公式如式(3)所示,表示真实值 y_i 与预测值 $\hat{y}_i$ 的差的平方和,即误差的平方和,代表模型未能解释的变异部分。

$$SST = \sum (y_i - \bar{y})^2 \quad (1)$$

$$SSR = \sum (\hat{y}_i - \bar{y})^2 \quad (2)$$

$$SSE = \sum (y_i - \hat{y}_i)^2 \quad (3)$$

2.1.1.2 判定系数指标

判定系数 R^2 用于表示预测值的波动大小与原始值的波动大小的比值,代表拟合优度。 R^2 可以用于衡量模型质量,数值越接近于1,说明拟合程度越高,也说明模型质量越好,如果 R^2 偏离1,则说明模型有待优化。当存在多个回归模型时,可以用 R^2 来选择最佳模型。

对于一元回归,常用 R^2 为:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (4)$$

对于多元回归,常用调整 $\bar{R}^2$ 为:

$$\bar{R}^2 = 1 - \frac{SSE/(n-p-1)}{SST/(n-1)} = 1 - (1 - R^2) \times \frac{n-1}{n-p-1} \quad (5)$$

其中, n 为样本数量, p 为自变量个数。

2.1.1.3 误差指标

使用平均绝对误差 MAE、平均误差率 MAPE 和根均方差 RMSE 作为误差指标表示模型的预测能力和误差大小。MAE 计算公式如式(6)所示,是预测值与真实值之间绝对差的平均值,直接反映了预测值与真实值之间的平均差距。MAPE 计算公式如式(7)所示,是预测误差的绝对值与真实值的百分比的平均值,常用于衡量预测相对误差的大小。RMSE 计算公式如式(8)所示,是预测值与真实值之差的平方和的平均值的平方根,常用于评估回归模型的预测精度。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (8)$$

2.1.2 定量预测模型的预测方法

定量预测步骤如图 1 所示。




图 1 定量预测步骤

a) 回归方程的显著性检验。检验方程的显著性,验证其是否适合进行回归分析,若方程显著性水平 Significance $F < \alpha$, α 一般取值为 0.05,表示可以使用回归分析。

b) 因素的显著性检验。检查各个自变量的显著性,若自变量显著性水平 $P < \alpha$, α 一般取值为 0.05,表示此因素有显著影响,否则应该删除此变量重新进行分析。

c) 回归方程的拟合优度检验。评价回归方程对样本数据的代表程度,判定系数 R^2 越接近 1,表示回归模型拟合程度越高。

d) 写出回归方程。根据回归系数得出回归方程。

e) 从业务层面解读回归方程的含义。从定性和

定量 2 个方面来描述变量间的关系。

2.2 资源利用率分析方法

对于云池承载业务的负荷变化,一般使用处理量指标,用以表征业务应用对系统联机处理事务能力的要求,通过 TPC-C 值^[16]来表达。TPC-C 值是指一分钟(秒)钟内系统需要处理的订单事务数量,单位为 tpmC (tpsC),计算公式如下:

$$TPC-C = [(TASK \times 80\%) / T] \times S \times F / C \quad (9)$$

其中, TASK 表示典型工作日平均业务交易总量,指的是应用系统需要处理的用户业务请求的总和。TASK×80% 表示假设典型工作日 80% 的业务交易集中在高峰时段。TASK×80%/T 即应用系统峰值每分钟处理的业务交易数。S 表示实际业务交易操作相对于标准 TPC-C 测试基准环境交易的复杂程度比例,简单事务的 S 值为 2~5,一般复杂事务为 6~12,较复杂事务为 13~16,高度复杂事务为 17~20。F 表示系统未来的业务交易量发展冗余预留,考虑服务器保留 30% 的冗余。C 表示服务器 CPU 利用率估算值。实际应用经验表明,服务器的 CPU 利用率高于 80% 则表明 CPU 的利用率过高,会产生系统瓶颈,而利用率处于 75% 时,是处于利用率最佳状态。因此,一般设定 $C=75\%$ 。

根据式(9)可以看出,对云池承载业务影响最大的因素是 CPU 利用率,通过大数据方差分析技术来预测 CPU 利用率瓶颈,用以指导 CPU 资源及时扩容,确保业务负荷运行在正常情况下,具有重要意义。

因此,为了解决专属私有云用户关心的资源利用率均衡问题,引入大数据方差分析技术,分析不同时间段对 vCPU 和内存利用率的波动性影响程度。在业务忙时,通过方差分析,判断不同时间段对 vCPU 利用率、内存利用率的波动影响,将对 vCPU 利用率存在显著性影响而对内存利用率不存在显著影响的虚拟机与分析结果相反的虚拟机调整至同一台宿主机,充分均衡资源利用率。

方差分析(Analysis of Variance, ANOVA)旨在研究一个影响因素的不同取值是否对目标变量产生了显著差异。该方法通过检验多个总体的均值是否相等来判断 1 个或多个分类型自变量对数值型因变量是否有显著影响。

2.2.1 方差分析的评估指标

2.2.1.1 总变异 SS_T

总变异 SS_T 表示受所有因素的影响而导致的目标变量波动大小,即目标变量的均差平方和。

$$SS_T = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2 \tag{10}$$

其中, $\bar{x}$ 为所有观测值的平均值, n_i 为各组样本总数, k 为分组数量。

2.2.1.2 组间变异 SS_A

组间变异 SS_A 表示受控制变量影响而导致的目标变量波动大小, 即各组均值离总均值的平方和。

$$SS_A = \sum_{i=1}^k n_i (\bar{x}_i - \bar{x})^2 \tag{11}$$

其中, $\bar{x}_i$ 为各组观测值的平均值。

2.2.1.3 组内变异 SS_E

组内变异 SS_E 是受其他因素 (主要是随机抽样) 引入的目标变量波动大小, 即各组的均差平方和。

$$SS_E = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2 \tag{12}$$

2.2.2 方差分析的方法

目标变量总的波动大小 SS_T 来源于 2 部分: 控制变量引起的组间变异以及随机抽样导致的影响组内变异 SS_E 。可通过定义新的统计量 F 值来判断目标变量波动原因, F 值的计算如下。

$$F = \frac{SS_A / (k - 1)}{SS_E / (n - k)} \tag{13}$$

如果目标变量主要是受控制因素的影响, 那么 $SS_A \approx SS_T$, 即 $SS_E \approx 0$, 此时 F 值应该足够大, 对应的概率 P 也应该足够小。若概率 $P < 0.05$, 表示因素对目标变量有显著影响, 否则表示没有显著影响。

3 研究结果

3.1 容量瓶颈预测结果

3.1.1 虚拟机 vCPU 利用率与运行天数的关系

选取某专属私有云平台虚拟机 vCPU 利用率与运行天数的运营数据, 建立定量预测模型, 模型模拟结果分别如表 1、表 2 和表 3 所示。

其中, Significance $F < 0.05$, 表明有统计学差异, 说明可以使用回归分析, 回归分析方程有效。运行天数

表 1 vCPU 利用率与运行天数模型拟合度

回归统计指标	数值
Multiple R	0.960
R^2	0.922
$\bar{R}^2$	0.921
标准误差	0.017
观测值	101.000

表 2 vCPU 利用率与运行天数模型显著性

	df	SS	MS	F	Significance F
回归分析	1.000	0.356	0.356	1 165.568	0.000
残差	99.000	0.030	0.000	—	—
总计	100.000	0.386	—	—	—

表 3 vCPU 利用率与运行天数模型系数

	Coefficients	标准误差	t Stat	P-value	Lower 95%	Upper 95%
Intercept	0.043	0.004	12.15	0.00	0.036	0.049
X Variable 1	0.002	0.00	34.140	0.000	0.002	0.002

因素的 P-value < 0.05 , 表示时间对 vCPU 利用率有显著影响。 R^2 接近于 1, 表示采用线性回归的拟合程度比较高。回归方程如下:

vCPU 利用率 = 0.002 × 天数 + 0.043 (14)

vCPU 利用率健康状态维持在 70%~80%, 当达到 70% 时, 需要考虑进行扩容。通过回归方程分析, 在运行 329 天后 vCPU 利用率达到 70.1%, 需要进行扩容。

3.1.2 虚拟机内存利用率与运行天数关系

选取虚拟机内存利用率与运行天数运营数据, 建立定量预测模型, 模型模拟结果分别如表 4、表 5 和表 6 所示。

表 4 内存利用率与运行天数模型拟合度

回归统计指标	数值
Multiple	0.961
R^2	0.924
$\bar{R}^2$	0.924
标准误差	0.041
观测值	101.000

表 5 内存利用率与运行天数模型显著性

方差分析	df	SS	MS	F	Significance F
回归分析	1.000	1.992	1.992	1 211.389	0.000
残差	99.000	0.163	0.002	—	—
总计	100.000	2.155	—	—	—

表 6 内存利用率与运行天数模型系数

	Coefficients	标准误差	t Stat	P-value	Lower 95%	Upper 95%
Intercept	0.144	0.008	17.654	0.000	0.127	0.160
X Variable 1	0.005	0.000	34.805	0.000	0.005	0.005

其中,Significance $F < 0.05$,表明有统计学差异,说明可以使用回归分析,回归分析方程有效。运行天数因素的 $P\text{-value} < 0.05$,表示时间对内存利用率有显著的影响。 R^2 接近于1,表示采用线性回归的拟合程度比较高。回归方程如下:

$$\text{内存利用率} = 0.005 \times \text{天数} + 0.144 \quad (15)$$

内存利用率健康状态维持在70%~80%,当达到70%时,需要考虑进行扩容。通过回归方程分析,在运行112天后内存利用率达到70.4%,需要进行扩容。

3.1.3 磁盘利用率与运行天数关系

选取磁盘利用率与运行天数运营数据,建立定量预测模型,模型模拟结果分别如表7、表8和表9所示。

表7 磁盘利用率与运行天数模型拟合度

回归统计	数值
Multiple R	0.950
R^2	0.902
$\bar{R}^2$	0.901
标准误差	0.003
观测值	101.000

表8 磁盘利用率与运行天数模型显著性

	df	SS	MS	F	Significance F
回归分析	1.000	0.006	0.006	910.591	0.000
残差	99.000	0.001	0.000	—	—
总计	100.000	0.006	—	—	—

表9 磁盘利用率与运行天数模型系数

	Coefficients	标准误差	t Stat	P-value	Lower 95%	Upper 95%
Intercept	0.309	0.001	617.305	0.000	0.308	0.310
X Variable 1	0.000 3	0.000	30.17	0.00	0.000	0.000

其中,Significance $F < 0.05$,表明有统计学差异,说明可以使用回归分析,回归分析方程有效。运行天数因素的 $P\text{-value} < 0.05$,表示时间对磁盘利用率有显著的影响。 R^2 接近于1,表示采用线性回归的拟合程度比较高。回归方程如下:

$$\text{磁盘利用率} = 0.000\ 3 \times \text{天数} + 0.309 \quad (16)$$

磁盘利用率健康状态维持在70%~80%,当达到70%时,需要考虑进行扩容。通过回归方程分析,在运行1302天后磁盘利用率达到70%,需要进行扩容。

3.2 资源利用率分析结果

选取某专属私有云平台A、B这2台虚拟机的运营数据,建立方差分析模型,分析在业务忙时,A、B 2台虚拟机的资源利用率情况。

3.2.1 A虚拟机方差分析结果

分别针对A虚拟机的vCPU利用率和内存利用率建立方差分析模型,模型模拟结果分别如表10、表11、表12以及表13所示。

表10 不同时间段对A虚拟机的vCPU利用率统计结果

组	观测数	求和	平均	方差
18:00-00:00	36.000	3.880	0.108	0.002
00:00-06:00	36.000	5.550	0.154	0.007
06:00-12:00	36.000	4.120	0.114	0.002
12:00-18:00	36.000	4.380	0.122	0.003

表11 不同时间段对A虚拟机的vCPU利用率方差分析结果

差异源	SS	df	MS	F	P-value	F crit
组间	0.046	3.000	0.015	4.413	0.005	2.669
组内	0.483	140.000	0.003	—	—	—
总计	0.529	143.000	—	—	—	—

表12 不同时间段对A虚拟机的内存利用率统计结果

组	观测数	求和	平均	方差
18:00-00:00	36.000	26.087	0.725	0.000
00:00-06:00	36.000	26.111	0.725	0.000
06:00-12:00	36.000	26.100	0.725	0.000
12:00-18:00	36.000	26.116	0.725	0.000

表13 不同时间段对A虚拟机的内存利用率方差分析结果

差异源	SS	df	MS	F	P-value	F crit
组间	0.000	3.000	0.000	0.509	0.677	2.669
组内	0.001	140.000	0.000	—	—	—
总计	0.001	143.000	—	—	—	—

从结果可以看出,不同时间段对A虚拟机的vCPU影响的 $P\text{-value}$ 为0.005,小于0.05,说明不同时间段对vCPU利用率有显著影响;不同时间段对A虚拟机的内存利用率影响的 $P\text{-value}$ 为0.68,大于0.05,说明不同时间段对内存利用率没有显著影响。

3.2.2 B虚拟机方差分析结果

分别针对B虚拟机的vCPU利用率和内存利用率建立方差分析模型,模型模拟结果分别如表14、表15、表16以及表17所示。

表 14 不同时间段对 B 虚拟机的 vCPU 利用率统计结果

组	观测数	求和	平均	方差
18:00—00:00	36.000	3.900	0.108	0.000
00:00—06:00	36.000	5.150	0.143	0.011
06:00—12:00	36.000	4.240	0.118	0.003
12:00—18:00	36.000	4.630	0.129	0.001

表 15 不同时间段对 B 虚拟机的 vCPU 利用率方差分析结果

差异源	SS	df	MS	F	P-value	F crit
组间	0.024	3.000	0.008	2.195	0.091	2.669
组内	0.511	140.000	0.004	—	—	—
总计	0.535	143.000	—	—	—	—

表 16 不同时间段对 B 虚拟机的内存利用率统计结果

组	观测数	求和	平均	方差
18:00—00:00	36.000	16.899	0.469	0.036
00:00—06:00	36.000	18.899	0.525	0.029
06:00—12:00	36.000	31.998	0.889	1.145
12:00—18:00	36.000	25.534	0.709	0.000

表 17 不同时间段对 B 虚拟机的内存利用率方差分析结果

差异源	SS	df	MS	F	P-value	F crit
组间	3.916	3.000	1.305	4.315	0.006	2.669
组内	42.353	140.000	0.303	—	—	—
总计	46.269	143.000	—	—	—	—

从表 14~表 17 可以看出,不同时间段对 B 虚拟机的 vCPU 影响的 P-value 为 0.091,大于 0.05,说明不同时间段对 vCPU 利用率没有显著影响;不同时间段对 B 虚拟机的内存利用率影响的 P-value 为 0.006,小于 0.05,说明不同时间段对内存利用率有显著影响。

综上所述,在云平台运营中,通过分析运维监控数据,可将符合 A 和 B 虚拟机情况的虚拟机热迁移至同一宿主机上,充分利用宿主机资源,解决资源利用率不均衡的问题。

4 总结

通过使用回归分析、方差分析等大数据分析技术对云平台运维数据进行建模分析和处理,得到运行天数与 vCPU、内存和磁盘利用率的关系模型,帮助预测云资源容量出现瓶颈的时间,得出了不同时间段对不同虚拟机 vCPU 和内存利用率的波动影响程度,用以指导均衡资源利用率。引入大数据分析技术,不仅为

专属私有云用户在运营过程中的预算申请提供了数据决策支撑,而且实现了运营的精细化管理,提升了运营效率和用户体验。

参考文献:

- [1] 李悦天. 电信运营商属地化行业云资源池优化设计与建设方案探讨[J]. 邮电设计技术, 2022(6): 19-24.
- [2] 刘寒, 张奎, 赵以爽, 等. 多场景云资源池监控技术和方案研究[J]. 邮电设计技术, 2021(9): 36-39.
- [3] 邹文仲, 邓力源, 张高峰, 等. 基于调度云平台通用分布式架构实践[J]. 南方电网技术, 2023, 17(9): 20-28.
- [4] 谢同磊, 邓莉, 曹振, 等. 基于 LSTM-Z 的云平台主机负载预测方法[J]. 计算机工程与设计, 2023, 44(9): 2561-2568.
- [5] 闫军锋, 唐青敏. 大规模云计算网络用户短时需求任务调度优化算法[J]. 现代电子技术, 2024, 47(6): 63-67.
- [6] 李英豪, 郭昊龚, 刘盼盼, 等. 基于时间卷积网络的云平台负载预测方法[J]. 计算机科学, 2023, 50(7): 254-260.
- [7] 李颖, 邵清, 王清云, 等. 面向云平台的免疫多目标优化调度算法[J]. 计算机应用与软件, 2024, 41(1): 278-284.
- [8] 都繁杰, 李静, 王亮, 等. MEF: 基于在线容错的云计算资源调度方法[J]. 计算机应用与软件, 2024, 41(3): 336-344.
- [9] 王艳, 张坤鹏, 纪志成. 基于可信服务的云资源智能优化与决策方法[J]. 信息安全, 2023, 23(2): 35-44.
- [10] 司徒, 梁建峰, 谢硕, 等. 深度学习驱动下 IaaS 云运维异常检测算法的研究进展[J]. 计算机科学, 2024, 51(z1): 718-725.
- [11] 姜杰, 段宏键, 曹华伟, 等. NUMA 感知的云平台负载调度系统[J]. 高技术通讯, 2025, 35(1): 20-36.
- [12] 李逸凡, 吴怡, 杨辉. 基于 OpenStack 私有云平台的资源动态调度方法[J]. 福建师范大学学报(自然科学版), 2025, 41(2): 1-8.
- [13] 陈红华, 崔翥龙, 王耀杰. 基于多种云环境的任务调度算法综述[J]. 计算机应用研究, 2023, 40(10): 2889-2895.
- [14] 丁宇, 袁麒麟, 才振功, 等. 云环境下自适应容器弹性扩容容优化方法[J]. 吉林大学学报(工学版): 1-13. (2025-03-14)[2025-05-14]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20241348>.
- [15] 陈海燕. 云资源数据传输效率评估数学模型的构建[J]. 宁夏师范学院学报, 2021, 42(7): 82-88.
- [16] 史惠康, 王泽胜, 张士宗, 等. 通用 CPU 性能基准测试研究综述[J]. 电子学报, 2023, 51(1): 246-256.

作者简介:

郭年庚, 毕业于北京科技大学, 工程师, 硕士, 主要从事算网数智大型复杂项目交付和运营服务领域工作; 赵帅, 毕业于北京工业大学, 工程师, 硕士, 主要从事算网数智大型复杂项目交付和运营服务领域工作; 杨海明, 毕业于美国仁斯利理工学院(RPI), 联通数字科技有限公司 CTO, 工程师, 博士, 主要从事算网数智领域工作; 许海峰, 毕业于北京理工大学, 工程师, 学士, 主要从事算网数智大型复杂项目交付和运营服务领域工作; 赵涵, 毕业于北京化工大学, 工程师, 硕士, 主要从事低空经济和算网数智领域工作。