

基于 PCA 降维的云资源状态监控数据压缩技术

洪斌¹ 邓波¹ 彭甫阳¹ 包阳² 冯学伟³

(北京市系统工程研究所 北京 100101)¹ (清华大学计算机科学与技术系 北京 100084)²

(信息系统安全技术国家重点实验室 北京 100101)³

摘要 云计算资源状态监控作为保障云服务质量和可靠性的重要自动化手段,必须从海量的监控数据中分析出各类云资源的真实状态信息。为了减少资源监控任务自身对云计算资源的消耗,提出一种基于 PCA(Principal Components Analysis)降维的监控数据的降维和筛选技术。监控数据转换利用 PCA 降维,将原始监控数据映射至若干主成分方向上,实现数据压缩。而监控数据筛选则着眼于在保留原始数据的前提下,筛选出关键监控指标以有效表征资源状态。基于 VICCI 云服务实验平台的实验结果证明,所提出的方法能够从多种监控数据中快速筛选出表征资源状态的核心数据,在保证状态监控效果的前提下,有效减少了监控任务所需处理的数据量。

关键词 云计算,状态监控,数据降维,大数据,主成分分析

中图分类号 TP311.5 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.8.004

Data Dimension Reduction Method Based on PCA for Monitoring Data of Virtual Resources in Cloud Computing

HONG Bin¹ DENG Bo¹ PENG Fu-yang¹ BAO Yang² FENG Xue-wei³

(Beijing Institute of System Engineering, Beijing 100101, China)¹

(Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China)²

(National Key Laboratory of Science and Technology on Information System Security, Beijing 100101, China)³

Abstract Cloud computing has become increasingly popular and cloud providers face serious problems as resource monitoring tasks become more and more complicated. As an effective approach to enhancing availability and reliability of cloud infrastructures, state monitoring system aims to detect anomalous state in cloud by analyzing monitoring data. To reduce the processed data volume, we proposed a data dimension reduction method based on PCA (Principal Components Analysis) with high fidelity in this article. The results of experiments carried on VICCI cloud service platform show that, our method can select the kernel metrics from hundreds of monitoring data types and sharply reduce the computing overload incurred by state monitoring tasks.

Keywords Cloud computing, State monitoring, Dimension reduction, Big data, PCA

1 引言

云计算通过远程租赁虚拟计算资源,将普通用户从底层硬件和基础软件的日常管理和维护中释放出来。随着这种商业模式的成功推广,云资源的管理者开始面临越来越复杂的系统维护任务。作为各类设施及虚拟资源的管理者,云服务商必须通过实时地监控数据采集和状态分析来保障云服务质量和可靠性。然而,大规模云服务的基础设施往往由成百上千台物理机及外围设备构成,通过网络向用户提供计算、存储、通讯等服务。这些物理设施和虚拟资源在运行过程中,将产生多种类、大体量的实时监控数据。通过状态监控系统,这些数据将被用于各类进一步的资源状态分析和异常监控任务,从而帮助云服务提供商管理和维护这些计算资源,例如通过计算任务迁移、资源动态分配以及补充瓶颈资源等方法,保障各类用户任务的正常执行和运行安全^[1];例如作为 Ama-

zon 针对 EC2(Elastic Cloud Computing)推出的资源监控服务,CloudWatch 向云服务的使用者提供了多达 200 余种不同类型的监控数据,包括 CPU 利用率、内存剩余量、等待队列中的进程数和磁盘 I/O 等^[2]。

在监控数据分析中,如果将所有监控指标考虑在内,数据分析任务将十分繁重,且存在大量重复冗余的数据处理和计算。此外,随意监控数据输入种类的增加,还可能引入一些导致状态误判的因素。为解决上述问题,本文提出一种基于 PCA 降维的监控指标降维和筛选办法。其能够针对不同的云资源应用场景,在保证状态监控有效性的前提下,帮助管理者获得符合监控要求的核心状态指标,将监控数据种类和体量缩小至合理的范围。

本文第 2 节给出当前国内外在云资源数据预处理领域的研究进展;第 3 节介绍逻辑主成分分析技术(PCA)的基本知识;第 4 节给出基于 PCA 的云资源状态监控数据降维和筛选

到稿日期:2015-07-29 返修日期:2015-12-28 本文受国家高技术研究发展计划(863 计划)(2013AA01A215),国家自然科学基金(61271252)资助。

洪斌 硕士,研究实习员,主要研究方向为云计算;邓波 博士,研究员,主要研究方向为软件工程;彭甫阳 博士,研究员,主要研究方向为云计算;包阳 博士生,助理研究员,主要研究方向为软件工程;冯学伟 硕士,助理研究员,主要研究方向为网络安全。

技术的应用场景,并对其进行形式化建模描述;第5节通过实验分析证明基于PCA的监控数据降维和筛选技术在云环境下的可行性和有效性;最后对全文进行总结,并简要介绍下一步工作。

2 相关工作

随着云计算的广泛使用以及用户对云服务质量(Quality of Service, QoS)的要求的不断提高,云环境下虚拟资源状态监控逐渐成为云资源管控的研究热点。

监控数据作为资源状态分析模型的输入,其选择是数据预处理的核心步骤。选择正确的监控指标不仅能够准确把握系统所处的真实状态,而且能够为下一步的监控数据分析任务有效地节约计算时间和资源消耗。一般可将云环境下资源的运行状态划分为正常、可疑、异常和数据不足4个状态类别:

(1)正常状态:当云环境下各种资源足够满足SLA(Service Level Agreement)中提出的功能性能要求,短期内不存在使用失败的风险时,称此时资源处于正常状态。

(2)异常状态:当云端所提供的资源不能满足SLA所约定的服务需求,并已经导致用户使用资源失败时,称资源处于异常状态。

(3)可疑状态:如果云端提供的资源虽然暂时未给用户使用带来明显影响,但资源性能不稳定或存在违背SLA协定的风险时,称资源处于可疑状态。

(4)数据不足:如果当前可供分析的监控数据不足以获得可靠结论或进行预测,则称之为数据不足。

当前国内外主要的云服务提供商均推出了不同层次的云监控服务。然而,这些监控工具往往停留在资源状态数据采集层面,并不提供数据预处理和深入分析的服务,无法直接对虚拟资源所处的真实状态进行判断。

在云资源状态监控和预测领域,相关研究已经开始着眼于解决原始监控数据体量巨大的问题。文献[5]利用监控数据的波动程度和均值水平来度量资源出现异常状态的可能性,并据此动态地选择监控数据采样密度。如图1所示,监控系统在系统状态平稳、出现异常风险较低时,采取较低的采样频率,从而降低数据体量。




图1 根据状态波动程度确定采样密度

文献[6-8]也是通过滑动滤波窗口(Sliding Filtering Window)等各类数据清洗技术来筛除无效状态数据,减少进入后续分析阶段的数据量。

但这些数据压缩方法往往先根据经验选择几种特定的监控指标类型(例如CPU利用率、磁盘I/O等),并在随后的数据预处理中减小数据样本的大小。其在选择状态数据进行分析时,未对状态数据类型选择的合理性进行量化分析,导致在对非关键监控数据的分析中耗费大量计算资源,甚至还可能影响对资源状态的准确判断^[9]。因此,在进行数据清洗和挖掘分析前,监控数据类型的有效选择是解决问题的关键。

实际上,特征提取一直都是模式识别、数据压缩、图像处

理等领域的关键工作。在监控数据筛选方面,类似“遍历搜索”的优筛选策略通过设定目标函数,并排查所有可能的数据子集,获得最优的数据类别组合^[13,14]。例如,文献[15]以互信息(Mutual Information)作为不同状态数据之间相关性的度量标准,排除冗余信息,筛选出理想的状态数据子集。源于信息论领域的互信息能够反映不同变量之间的相互包含程度,即某随机变量中包含关于其他随机变量的信息容量。然而,这种方法需要对 n 种状态数据的所有组合进行比较。当待选状态指标类型较多时, 2^n 种不同组合导致计算复杂度呈指数增长。由此可见,基于“遍历搜索”的优筛选策仅适用于类别较少的数据筛选情景,难以应对云资源中大量重叠的监控数据筛选。

3 主成分分析技术

类似于K-L分解(K-L Decomposition, KLD)和奇异值分解(Singular Value Decomposition, SVD)等数据压缩和特征抽取方法,主成分分析法(Principal Component Analysis, PCA)的核心也是正交分解(Proper Orthogonal Decomposition, POD)。通过使用正交变换,将若干可能具有相关性的观测变量线性地转换为一组无关变量,即选择新的相互正交的空间基向量(即主成分, Principal Component)来表达数据。随后依据数据压缩要求,以少数几种最为关键的主成分向量为基(Basis),并通过重构原始数据实现数据降维。

3.1 数据的相关性

考虑两组均值为零的数据向量 a 和 b ,通过计算协方差 σ_{ab}^2 来衡量二者间的相关性。

定义1 数据向量 a 和 b 之间的协方差 σ_{ab}^2 :

$$\sigma_{ab}^2 = \frac{1}{2} ab^T$$

数据向量 a 和 b 之间的相关性越强,则二者间的协方差值越大。特别地,有以下两个事实:

1) $\sigma_{ab}^2 = 0$, 当且仅当数据向量 a 和 b 之间不存在任何相关性,此时也称数据向量 a 和 b 正交;

2) $\sigma_{aa}^2 = \sigma_a^2$, 当且仅当数据向量 $a=b$ 。

类似地,考虑数据维数为 m 、样本数为 n 的数据向量矩阵 X ,有如下定义。

定义2 有 $m \times n$ 维观测数据矩阵 X ,矩阵的 m 行表示不同的观测维度获得的数据项(Measurement Types),矩阵的 n 列则表示特定时刻所有观测维度采集到的观测数据(Number of Trails):

$$X = \begin{bmatrix} x_1 \\ \vdots \\ x_m \end{bmatrix}$$

定义3 有 $m \times n$ 维的观测数据矩阵 X ,定义其协方差矩阵 C_X :

$$C_X = \frac{1}{n} X X^T$$

注意到协方差矩阵 C_X 是维数为 $m \times m$ 的方阵,且其对角线上元素 c_{ii} 表示观测维度 i 上数据的方差 σ_i^2 ,其他位置元素 c_{ij} 则表示观测维度 i 与观测维度 j 上获得数据的协方差 σ_{ij}^2 。

定理1 $m \times n$ 维观测数据矩阵 X 中的测量数据互不相关的充要条件为:

$$\forall i \neq j, \sigma_{ij}^2 = 0$$

通过计算协方差矩阵 C_X 可以度量所有观测维度之间的

相关性。协方差 σ_{ij}^2 越大,则对应维度上的测量数据的相关性越明显,在数据预处理阶段需要辨识并剔除在这类维度上获得的观测数据。

3.2 主成分分析

考虑上述 $m \times n$ 维观测数据矩阵 X ,其协方差矩阵 C_X 中元素 $c_{ij} = \sigma_{ij}^2$ 。主成分分析通过对原始数据进行线性变换,将其重新表达在一组正交基所构成的多维空间中,并且数据在新的空间基上表现出最大的离散度。此时,各维度数据间的协方差为零,即变换后的数据矩阵的协方差矩阵应为对角阵。同时,该协方差矩阵对角线上的值为不同主成分(基)上数据的方差(即数据离散程度),该值度量了各主成分的重要程度。最后,根据数据压缩要求,选择若干主成分为基构成新的低维空间,重新表达原始数据,实现数据降维。

3.2.1 协方差矩阵对角化

对原始数据进行适当的线性变换,即寻找正交阵 P ,获得新的数据表达 $Y=PX$,使其协方差矩阵 S_Y 为对角阵。此时,矩阵 P 的行向量即为原始数据矩阵 X 在新维度下的主成分向量。

定理 2 有任意 $m \times n$ 维矩阵 X ,则 X 与 X 的转置矩阵的乘积是对称矩阵:

$$A=XX^T, a_{ij}=a_{ji}$$

定理 3 对称矩阵 A 可以实现如下特征分解,其中矩阵 D 是由矩阵 A 特征值组成的对角矩阵,矩阵 E 的列是矩阵 A 特征值对应的特征向量:

$$A=EDE^T$$

值得注意的是, $m \times m$ 维实对称矩阵 A 一定可以找到 m 个单位正交特征向量,其对应的特征值可能重复。设这 m 个特征向量为 e_1, e_2, \dots, e_m ,则上述矩阵 E 和斜对角矩阵 D 的形式如下:

$$E=(e_1, e_2, \dots, e_m)$$

$$D=\begin{pmatrix} \lambda_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_m \end{pmatrix}$$

注意到矩阵 $Y=PX$ 的协方差矩阵可以写成如下形式:

$$C_Y=\frac{1}{n-1}P(XX^T)P^T$$

此时选取转换矩阵 $P=E^T$,能够使得 C_Y 为对角阵,即:

$$C_Y=\frac{1}{n-1}D$$

至此,通过计算原始数据矩阵 XX^T 的特征向量,并用其构成的转换矩阵 P 作用于 X ,能够获得协方差矩阵为对角阵的新数据矩阵 Y 。

3.2.2 低维空间基排序

为了将原始数据压缩至 $D(D < m)$ 维,首先应重新选择 D 个主成分构成低维空间。同时,为了最大程度保留原始数据信息,需要对各主成分的重要程度进行度量。一般而言,数据在某维度上的离散程度越大,则该维度上的信息量越大,对表征原始数据也越为重要。

例如,对图 2 中离散的二维数据点进行主成分分析,发现其在主成分方向 A 上呈现较大的离散度(注:图 2 中虚线表示该方向上的方差值分布),并且大于主成分方向 B。一般认为主成分方向 A 保留的信息多于主成分方向 B,当后续应用要求将数据压缩至一维时,应该选择主成分方向 A 作为该维的基准坐标。




图 2 主成分方向的选择

考虑利用矩阵 XX^T 的特征向量构成转换矩阵 P 变换获得的矩阵 Y ,其协方差矩阵为对角阵。根据定理 3 可知,其对象线上的元素为各特征向量对应的特征值。由协方差矩阵的定义可知,这些元素实际上也是变换后的数据在不同主成分(空间基)方向上的方差。按照特征值大小排序,实际也给出了不同主成分的重要程度的排序。

定义 4 原始数据维度为 m ,变换后协方差矩阵的特征值按降序排列为 $\lambda_1, \dots, \lambda_m$,则要求压缩后的数据保真度 Fid 大于阈值 γ 时,数据维度 D 应满足:

$$Fid=\frac{\sum_{i=1}^D \lambda_i}{\sum_{j=1}^m \lambda_j} > \gamma$$

数据保真度的阈值 γ 因应用不同而异,在数据预处理时,应根据定义 4 中的公式确定数据降维所需的最少主成分个数 D 。

3.2.3 重新表达数据

根据数据压缩要求和主成分重要程度排序,选择若干主成分向量对原始数据进行从高维空间向低维空间的线性变换,实现数据压缩。

定理 4 假定被选中的特征值为 $\lambda_1, \dots, \lambda_D$,其对应的特征向量分别为 e_1, \dots, e_m ,则数据压缩过程为:

$$Y=PX=(e_1 e_2 \dots e_D)^T \cdot X$$

对于特定应用,可能需要对被压缩的数据进行还原。此时只需在压缩后的数据矩阵的左侧乘以变换矩阵 P 的逆矩阵 P^{-1} 即可。由于 P 为正交阵,因此有 $P^{-1}=P^T$ 。

定理 5 假设还原后的数据矩阵为 Z ,则压缩数据的还原过程为:

$$P=P^{-1}Y=P^T Y$$

实际上,由于数据降维的过程已经丢失了部分数据信息,还原后的数据必然与原始数据存在差异。该过程损失的数据信息量的衡量指标可参考定义 4 中保真度 Fid 进行计算。

4 监控数据降维和筛选技术

全面的云资源状态实时监控作为一种复杂且繁重的计算任务,容易给云服务自身带来不可忽略的计算负载^[1]。特别是在对资源进行深入的状态分析时,将会涉及到原始数据转换、模型参数迭代计算等,冗余的监控指标数据可能导致计算复杂度呈指数增长。本文提出一种基于 PCA 降维的监控数据的降维和筛选技术,其能够从多种监控数据中快速筛选出影响资源状态的核心数据,在保证状态监控效果的前提下,有效降低监控任务所需处理的数据量。

4.1 云资源状态监控系统

通过网络,云计算服务提供商向用户提供的计算资源和软件服务包括计算、存储、网络、应用软件等。同时,云服务提供商必须保障这些资源或服务达到用户要求的性能指标,否则需要向用户支付损失赔偿。通过将各类分布式监控系统部署在提供云服务的服务器或物理计算节点上,便能实现云环

境下资源的性能监控数据的采集,获得原始监控数据。

如图3所示,云环境下资源状态监控数据预处理系统是云资源监控系统的子系统,其主要任务是对原始监控数据进行清洗去冗等预处理,以方便后续数据挖掘分析。本文提出的基于PCA的状态数据筛选技术是对数据预处理环节的技术补充。整体的监控构架还包括:资源状态监控数据采集存储系统、监控数据分析处理系统和预测结果反馈展示系统。

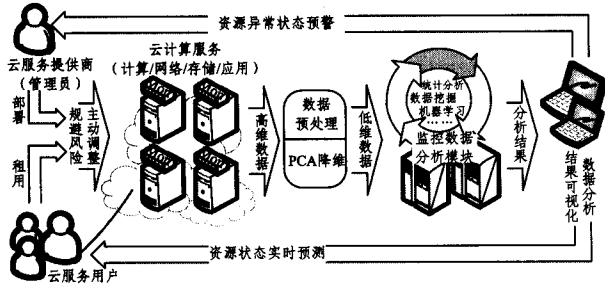


图3 云资源监控系统构架

4.2 监控数据的特点

随着各类云服务的规模和复杂度不断增加,运行中产生的实时监控数据体量也迅速增长。除了数据规模庞大之外,云资源的状态监控数据还具有如下特点:

1)不同的监控数据之间相互耦合,个别指标之间存在明显的相关性。例如, Linux 系统的虚拟机监控指令“vmstat”采集的指标中,虚拟机实例的已使用虚拟内存大小(swpd)和剩余内存空间大小(free)之间就存在较强的关联性。当系统开始使用虚拟内存时,一般可以认为系统的内存已经耗尽。

2)对于不同的云资源应用场景,能够准确反映资源状态的关键监控指标也有所不同。例如,对于 MapReduce 程序等计算密集型应用,CPU 使用率和任务线程数等将是关键的监控指标。而对于使用云资源提供 Web 服务的情况,数据包首发数量和网络带宽等将是管理者首先要关注的监控指标。

在监控数据分析中,如果将所有监控指标考虑在内,数据分析任务将十分繁重,且存在大量重复冗余的数据处理和计算。此外,随意增加监控数据输入的种类还可能引入一些导致状态误判的因素。为解决上述问题,考虑一种基于 PCA 降维的监控指标降维和筛选办法,以能够针对不同的云资源应用场景,在保证状态监控有效性的前提下,帮助管理者筛选出符合监控要求的核心状态指标,将监控数据种类和体量缩小至合理的范围。

4.3 监控数据降维与筛选算法

分布在云环境中的监控系统按照一定的频率采集资源状态数据,并将其直接反馈给后续的数据分析系统,数据压缩是数据预处理的重要环节之一。为方便讨论,表1对下文中出现的符号作统一说明。

表1 符号说明

符号	含义说明
m	监控指标类型数
n	采样长度
D	压缩后的数据维度
Fid	数据保真度
γ	数据保真度阈值(用户定义)
λ_i	矩阵特征值(按降序排位为 i)
IF_i	监控指标 i 的影响因子
e_i	特征值 λ_i 对应的特征向量
x_i	监控指标 i 的采样数据向量
y_i	压缩后的监控指标 i 的数据向量

4.3.1 监控数据降维算法

用户通过租赁计算资源的形式,将应用部署在所属的虚拟资源上。这里假定监控系统采集了在 n 个连续采样点对某虚拟资源的 m 种状态指标的原始数据。为了减少后续数据分析算法的输入数据体量,考虑采用基于 PCA 的数据降维算法对原始数据进行预处理。要求在保证用户指定的数据保真度阈值的前提下,尽可能用最小的数据维度表征原始数据,作为后续分析处理的输入。下面给出该算法简化后的伪代码。

算法1 监控数据的主成分分析

输入:原始监控数据 $x_1 x_2 \dots x_m$; 数据保真度阈值 γ
输出:降维后的关键状态数据 $y_1 y_2 \dots y_D$; 数据保真度 Fid

```

 $XX^T = [x_1 x_2 \dots x_m]^T \cdot [x_1 x_2 \dots x_m]$ ;
//计算矩阵  $XX^T$  的特征值和特征向量;
Sort  $\lambda$  in descending order:  $\lambda_1 > \lambda_2 > \dots > \lambda_m$ ;
 $D=0$ ;  $Fid=0$ ;
WHILE( $Fid < \gamma$ )

```

```

{
     $D=D+1$ ;
     $Fid = \frac{\sum_{i=1}^D \lambda_i}{\sum_{j=1}^m \lambda_j}$ ;
    //筛选数据以满足保真度要求
}
 $P = [e_1 e_2 \dots e_D]$  //输出变换矩阵 P

```

由于在云环境中运行任何计算任务都将给云资源本身带来负载,因此在设计算法时必须重点考虑算法的计算复杂度。算法1中涉及到的运算包括矩阵乘法、特征值和特征向量的计算、排序以及求和运算等。使用表1中的符号,其计算复杂度如表2所列。可以看出,算法1的计算复杂度为 $O(m^2 \cdot n)$ 。数据筛选任务在计算任务运行前进行,属于单次运行的离线任务,因此算法1的计算复杂度可以接受。

表2 算法复杂度分析

运算内容	算法复杂度
XX^T	$O(m^2 \cdot n)$
PX	$O(d \cdot m \cdot n)$
XX^T 特征值计算	$O(m^3)$
XX^T 特征向量计算	$O(m^3)$
$\lambda_1 \dots \lambda_m$ 排序	$O(m \cdot \log m)$

在监控阶段,数据预处理系统需要对原始监控数据进行实时的在线降维,如算法2所示。该过程相对简单,只涉及到矩阵乘法运算,算法复杂度为 $O(d \cdot m \cdot n)$ 。

算法2 监控数据在线压缩算法

输入:实时监控数据 $x = [x_1 x_2 \dots x_m]$; $p = [e_1 e_2 \dots e_D]$
输出:映射后的关键状态数据 $y = [y_1 y_2 \dots y_D]$, $y = [e_1 e_2 \dots e_D] \cdot [x_1 x_2 \dots x_m]$
//将数据维度从 m 降至 D

总之,算法1实现了基于PCA技术的主成分提取与排序,算法2将原始数据按照数据压缩要求向重要主成分方向映射,获得低维度下更为简洁的新数据。

4.3.2 监控数据筛选算法

上文提到的数据降维算法将原始数据按照数据压缩要求向重要主成分方向映射。然而,这种数据压缩方法对CPU利用率、磁盘余量等原始数据进行了重新组合,压缩后获得的监控数据不再具有明确的物理意义。

实际上,云资源的使用者和供应商经常需要根据明确的资源监控指标来对处于瓶颈状态的计算资源进行资源补充或

任务调度。此外,在云服务发生异常故障时,也需要依据直观的监控指标(如 CPU 利用率、网络流量等)进行故障溯源。因此,有必要筛选并保留若干关键原始监控数据,以方便云资源管理。

本文提出一种监控数据筛选办法,根据主成分分析结果,度量各个状态指标的重要程度,从而直接筛选出关键若干监控指标。要求在保证用户指定的数据保真度阈值 γ 的前提下,尽可能用最小的原始监控数据表征资源状态。这里定义各个状态监控数据的影响因子 IF 如下。

定义 5 有 $m \times n$ 维的观测数据矩阵 X ,其协方差矩阵的特征向量为 $e_1, e_2 \dots e_m$,对应特征值为 $\lambda_1 > \lambda_2 > \dots > \lambda_m$,定义监控指标的影响因子 IF_i 为:

$$IF_i = \frac{\sum_{j=1}^m \lambda_j}{\sum_{k=1}^m \lambda_k} + \frac{e_j[i]}{\sum_k e_k[k]}$$

定理 6 对于定义 5 中的监控指标 i 的影响因子 IF_i ,有如下结论:

$$\sum_{i=1}^m IF_i = 1$$

由定义 5 和定理 6 可知,利用算法 1 的主成分结果可以对 m 个原始监控数据的重要性进行度量并排序,从而从大量的监控指标中筛选出若干关键指标,在保证数据保真度的同时,直接实现数据降维,其算法描述如下。

算法 3 监控数据筛选算法

输入:数据矩阵 X 的特征向量 $e_1, e_2 \dots e_m$,特征值 $\lambda_1 > \lambda_2 \dots \lambda_m$,数据保真度阈值 γ

输出:监控指标 i 的影响因子 $IF_1, IF_2 \dots IF_m$,数据保真度 Fid ,关键状态数据 $x_{key} = [x_1, x_2 \dots x_D]$

FOR $i=1$ TO m

$$\{ IF_i = \frac{\sum_{j=1}^m \lambda_j}{\sum_{k=1}^m \lambda_k} + \frac{e_j[i]}{\sum_k e_k[k]} \}$$

//计算各状态数据的影响因子 IF_i

Sort IF_i in descending order $IF_1 > \dots > IF_m$;

//将 IF_i 按降序排列

$D=0$;

WHILE($Fid < \gamma$)

{

$D=D+1$;

$$Fid = \frac{\sum_{i=1}^D IF_i}{\sum_{i=1}^m IF_i}$$

//筛选数据以满足保真度要求

}

$x_{key} = [x_1, x_2 \dots x_D]$; //将数据维度从 m 降至 D

如上文所述,对于不同的云资源应用场景,能够准确反映资源状态的关键监控指标也有所不同。当使用云资源运行新的计算任务时,用户应当重新构建训练数据集,并运行数据筛选算法确定关键的资源状态监控指标。进一步的研究可以考虑使用聚类算法等对运算任务归类,同类计算任务和特定组合的监控指标挂钩,在计算任务切换时,直接使用对应的已知的数据筛选和降维方案。

5 实验研究

5.1 实验环境设置

本文的实验环境构建于 VICCI 云计算平台^[5]上。该平

台由普林斯顿大学在 PlanetLab 网络计算平台基础之上开发并维护。构成 VICCI 云计算平台的集群具有类似的配置,参数明细如表 3 所列。该平台不仅能够支持虚拟机的创建、部署和销毁,同时还支持 MPI 和 Hadoop 等并行计算框架,是适用于开展云计算研究的基础设施服务云(IaaS)。

表 3 VICCI 云平台集群参数配置说明

名称	型号	数量	配置	参数
服务器	DELL	70	CPU	X5650 12 核
	R40		RAM	48G
	Power		硬盘	3TB
	Edge		网卡	1GE(双卡)
交换机	Quanta	4	端口	1GE (48 端口)
	Pronto 3290			

本文通过 VMSTAT 工具获取资源状态监控数据,按照监控对象和层次不同,可分为内存、系统、进程、CPU、I/O 和磁盘共 6 大类 16 个指标。VMSTAT 采集的资源状态指标如图 4 所示,可以看出虚拟机的 CPU 和内存是重点监测的部分,其分别对应 4 个相关指标。而系统、磁盘、进程和 I/O 作为一般监测对象,VMSTAT 仅仅分别监测 2 个核心的相关指标。本次实验任务即是从这些指标中选择对应不同应用场景的关键指标,通过数据转换或筛选实现数据压缩。




图 4 VMSTAT 云资源监控指标

5.2 实验结果

本文采用 Hadoop 自带的 Benchmark 排序程序作为基础测试程序,实验规模约为 70 台虚拟机。实验使用第 4 节中的算法 1 对 VMSTAT 工具采集到的状态监控数据进行降维分析和数据筛选。这里首先列出实验的主要发现:

(1)基于 PCA 的数据转换算法能够使用较少维度的新数据保留原始监控数据的状态信息;

(2)基于 PCA 的数据筛选算法能够从多种监控指标中筛选出少数的关键原始数据,保留监控数据物理意义的同时实现了数据压缩;

(3)本文提出的两种数据压缩方法均能使用较少的监控数据表征资源状态信息,实现异常状态的实时监控和预警。

5.2.1 主成分贡献度及数据完整性

按照原始检测数据在各主成分方向上离散程度由高至低的顺序,可以对其进行贡献度排序。在实验中逐步增加主成分个数,观察增加的主成分对数据保真度 Fid 贡献的变化情况。

图 5 中的直方图显示了各主成分的信息对保留原始数据信息的贡献,曲线显示了仅选取若干重要主成分时,能够保留的数据完整度。可见在以消耗 CPU 为主的应用情景下,原始监控数据存在明显的冗余。

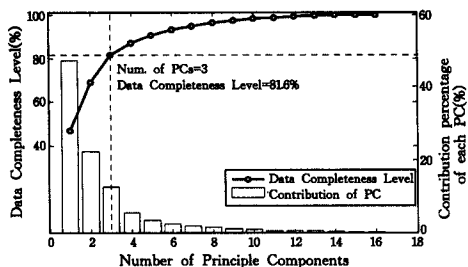


图5 主成分贡献度及数据完整度

在一般性的监控要求下,可以将原始采集到的16种监控数据映射至最重要的主成分方向上,将数据压缩至3维或4维。同时,这种数据压缩仍然极大地保留了虚拟资源的状态信息。例如,图5中的前3个主成分方向上的数据就保留了全部原始信息的81.6%,其中最重要的主成分方向就存储了47.1%的数据特征信息。

5.2.2 筛选关键监控数据

仍然以 Benchmark 排序程序作为基础测试程序,根据上节中的主成分分析结果,分别计算各监控指标对应的影响因子 IF ,将其作为其重要程度的度量标准,从而直接筛选出最为关键的若干监控指标。当用这些指标来表征被监控资源的状态时,依据定理5还可以获得其对应的数据完整度 Fid 。




图6 根据影响因子筛选关键指标

从图6中可以看出,在6大类16种监控指标中与内存、CPU和I/O相关的5个指标的影响因子 IF 明显大于其他状态指标。按照其重要程度降序排列,分别是空闲CPU时间(id)、用作缓冲的内存量($buff$)、用作缓存的内存量($cache$)、每秒读取块数(bi)和系统进程执行时间(sy)。以上5个指标的影响因子之和约为60%,也就是说,这里使用5个监控指标就可以表征出原先16个指标所包含所有信息的60%。一般而言,云计算资源的管理者可以对上述5类关键指标的变化趋势进行深入挖掘分析,从而获得对云资源状态的实时监控,以及对可能潜在的异常状态进行提前预警。




图7 数据降维与筛选效果对比


从图7可以明显看出,基于PCA的数据转换方法能够用更少的数据维度来表征原始数据,仅用3个维度即可保留80%的信息。而数据筛选算法在保留原始数据的物理意义的同时,需要使用更多的监控指标来表征资源状态,实验中使用

10个监控指标才保留了83.7%的状态信息。数据转换具有更明显的数据压缩效果。


5.2.3 基于数据压缩的状态实时监控

本文提出两种云资源状态监控数据的降维方法,即监控数据转换和数据筛选。本节将基于故障注入实验对其实际应用效果作验证。实验在运行的虚拟机中注入CPU故障,其占用大量CPU轮转周期,并不断测试运行于该虚拟机上的应用的服务响应时间。观察压缩或筛选后的监控数据,能否及时地反映系统故障,实现虚拟资源的有效监控。


图8为云资源服务响应时间与重要主成分的变化趋势比较。其中,图8(a)为服务响应时间变化曲线,可以看出在虚线圈出的时段内,云资源所提供的服务出现了明显的服务响应延迟,一般认为云资源此时处于异常状态。图8(b)、图8(c)、图8(d)分别为原始数据在第1、2、3主成分方向上映射结果的变化曲线。其中,图8(b)为原始数据在最重要的主成分方向上的映射,可以看出其与服务响应时间变化存在对应关系:在资源状态异常时段,其值也相应地明显高于正常值。云资源运营者可以根据这些转换后的资源状态指标,推断云资源所处的真实状态。同样,图8(d)也体现出这种对应关系。而图8(c)中的曲线变化与服务响应时间的变化不相关,其可能表征了云资源的其他状态特征,是检测其他类型异常状态的重要指标。




(a) 服务响应时间变化曲线



(b) 第1主成分方向上映射结果的变化曲线



(c) 第2主成分方向上映射结果的变化曲线



(d) 第3主成分方向上映射结果的变化曲线

图8 云资源服务响应时间与重要主成分的变化趋势比较

上文提到的监控数据筛选结果表明,在16个监控指标中,空闲CPU时间百分比(id)最为关键,即最能表征资源状态变化。图9将空闲CPU百分比与云资源服务响应时间的变化趋势进行了对照。可以看出,在资源状态异常时段,空闲CPU百分比也相应地明显高于正常值,并在时间上有所提前。云资源管理者仅仅根据该指标就可以对资源状态进行分析,实现异常状态的检测与预警。图10列举了若干在数据筛选阶段被筛选的监控数据,从其变化趋势也可以看出,对这些监控数据进行深入的数据挖掘分析将很难获得与资源状态相关的有效信息。




图9 云资源服务响应时间与关键指标(即 CPU 空闲百分比 id)变化趋势比较

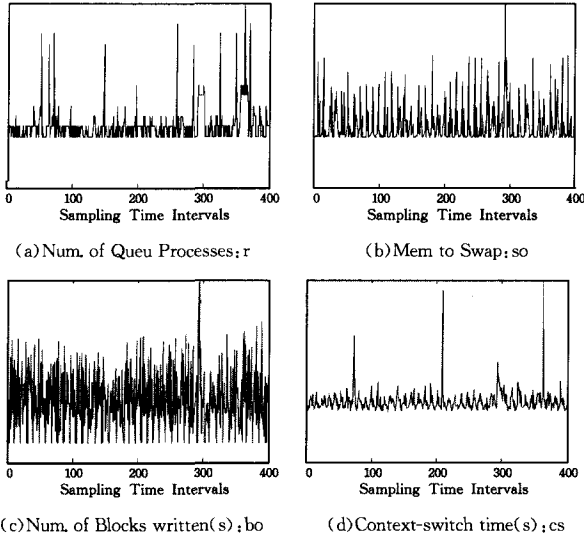


图10 若干被筛选的监控指标变化趋势

必须指出的是,图8和图9中显示的部分关键主成分方向或原始数据恰好与实验中出现的异常状态类型(即服务响应时间延迟)存在明显关联,但不能因此忽略对其他关键指标的监控与挖掘分析。在实际应用中,较为可靠的策略是基于PCA分析结果,在满足数据完整度(仿真度 Fid)的前提下确定若干关键数据维度,并对其进行实时的全面分析。这样,当资源运行中出现异常时,上述经过降维、筛选的监控数据中也将出现与之相关的数据变化,但具体如何体现、体现在哪个监控指标上则与实际应用相关。

结束语 本文提出一种基于PCA降维的监控数据的降维和筛选技术,其能够从多种监控数据中快速筛选出影响资源状态的核心数据,在保证状态监控效果的前提下,有效降低监控任务所需处理的数据量。监控数据降维基于PCA分析结果,将原始监控数据映射至若干主成分方向上,实现数据压缩。而监控数据筛选则着眼于在保留原始数据的前提下,筛选出关键监控指标,实现资源状态表征。基于VICCI云服务实验平台的实验结果表明,本文所提出的方法能够较好地实现预期的数据压缩目标。

后续的研究将聚焦于压缩后监控数据的挖掘分析^[11,12]。利用数据降维或筛选技术,现将空数据体量降低至合理范围,随后利用聚类分析、统计建模等多种数据分析手段从压缩后的数据中挖掘出云资源的状态信息。特别地,由于反映资源状态的监控指标往往不止一种,后续研究将着重考虑各指标分析结果的整合和协同增效。此外,作为PCA技术的扩展,KPCA技术(Kernel PCA)能够处理通常在线性空间难于线

性分类的数据点(即相互之间存在冗余),能够在更高维度上找到合适的高维线性分类平面,进一步发现数据间的无效重叠。后续的研究还将考虑将KPCA技术应用于云资源数据筛选领域,并与本文述及的基于PCA技术的筛选结果进行比较,从而给出更有效的云资源状态监控数据筛选方案。

参考文献

- [1] Aceto G, Botta A, De Donato W, et al. Cloud monitoring: A survey[J]. *Computer Networks*, 2013, 57(9): 2093-2115
- [2] Amazon CloudWatch developer Guide[OL]. <http://docs.aws.amazon.com/AWSCloudWatch/latest/DeveloperGuide/acw-dg.pdf>
- [3] Jolliffe I. Principal component analysis[M]. John Wiley & Sons, Ltd, 2002
- [4] Moore B C. Principal component analysis in linear systems: Controllability, observability, and model reduction[J]. *IEEE Transactions on Automatic Control*, 1981, 26(1): 17-32
- [5] Meng S, Liu L. Enhanced monitoring-as-a-service for effective cloud management[J]. *IEEE Transactions on Computers*, 2013, 62(9): 1705-1720
- [6] Meng S, Kashyap S R, Venkatramani C, et al. Resource-aware application state monitoring[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2012, 23(12): 2315-2329
- [7] Mi H, Wang H, Zhou Y, et al. Toward fine-grained, unsupervised, scalable performance diagnosis for production cloud computing systems[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2013, 24(6): 1245-1255
- [8] Pannu H S, Liu J, Guan Q, et al. AFD: Adaptive failure detection system for cloud computing infrastructures[C] // 2012 IEEE 31st International Performance Computing and Communications Conference (IPCCC). IEEE, 2012: 71-80
- [9] Zheng Pai, Cui Li-zheng, Wang Hai-yang, et al. A data placement Strategy for Data-Intensive Applications in Cloud[J]. *Chinese Journal of Computer*, 2010, 33(8): 1472-1480 (in Chinese)
- [10] 郑湃, 崔立真, 王海洋, 等. 云计算环境下面向数据密集型应用的数据布局策略与方法[J]. *计算机学报*, 2010, 33(8): 1472-1480
- [11] Zhu Xia, Luo Jun-zhou, Song Ai-bo, et al. A multi-Dimensional Indexing for Complex Query in Cloud Computing[J]. *Journal of Computer Research and Development*, 2015, 50(8): 1592-1603 (in Chinese)
- [12] 朱夏, 罗军舟, 宋爱波, 等. 云计算环境下支持复杂查询的多维数据索引机制[J]. *计算机研究与发展*, 2015, 50(8): 1592-1603
- [13] Chandola V, Banerjee A, Kumar V. Anomaly detection: A survey [J]. *ACM Computing Surveys (CSUR)*, 2009, 41(3): 75-79
- [14] Salfner F, Lenk M, Malek M. A survey of online failure prediction methods[J]. *ACM Computing Surveys (CSUR)*, 2010, 42(3): 1283-1310
- [15] Timusk M A. A unified method for anomaly detection in unsteady systems[M]. 2006
- [16] McBain J, Timusk M. Feature extraction for novelty detection as applied to fault detection in machinery[J]. *Pattern Recognition Letters*, 2011, 32(7): 1054-1061
- [17] Kinney J B, Atwal G S. Equitability, mutual information, and the maximal information coefficient[J]. *Proceedings of the National Academy of Sciences*, 2014, 111(9): 3354-3359