

数据中心内服务器能耗数据采集及特征分析

周清^{1,2}, 张谱晟^{1,2}, 沈子钰^{1,2}, 李云^{1,2}

(1. 南京邮电大学计算机学院, 南京 210023; 2. 江苏省大数据安全与智能处理重点实验室, 南京 210023)

摘要: 数据中心的高能耗低能效问题正受到广泛关注与研究, 但目前没有公开的数据中心内服务器能耗数据集供研究人员使用, 且现有过滤式特征选择并不能满足运维人员的需求。为此, 提出了一套模拟数据中心内服务器运行状态的仿真环境架构, 基于该架构采集了服务器运行各类任务时的多项性能指标和能耗数据。然后将基于因果关系的特征选择应用于能耗数据集的特征分析中, 构建出可解释的特征子集和能耗预测结果。实验结果表明, 因果特征子集大小约为过滤式特征子集大小的 1/3 到 1/6, 并且使用因果特征子集训练的模型在 75% 的情况下都取得了最优预测精度。

关键词: 数据中心; 服务器; 仿真环境架构; 数据采集; 特征选择

中图分类号: TP391.4 **文献标志码:** A

Data Collection and Feature Analysis of Server Energy Consumption in Data Center

ZHOU Qing^{1,2}, ZHANG Xusheng^{1,2}, SHEN Ziyu^{1,2}, LI Yun^{1,2}

(1. School of Computer Science and Technology, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;
2. Jiangsu Key Laboratory of Big Data Security and Intelligent Processing, Nanjing 210023, China)

Abstract: The problem of high energy consumption and low energy efficiency of data center has been paid extensive attention to and investigated by researchers. However, there is no public dataset of server energy consumption for researchers to use, and current filter feature selection can not satisfy requirements of engineers. Here, a simulation environment architecture is proposed to simulate the running state of servers in the data center. Based on the proposed architecture, performance parameters and energy consumption data of server are collected when the server as running various tasks. Causal feature selection is applied to the feature analysis of energy consumption datasets, and thus an interpretable feature subset is constructed and the energy consumption forecast results are obtained. Experimental results show that the size of causal feature subset is about 1/3 to 1/6 of the size of filter feature subset, and the model trained with causal feature subset achieves the optimal prediction accuracy in 75% of the cases.

Key words: data center; server; simulation environment architecture; data acquisition; feature selection

引言

数据中心是基于网络的为用户提供计算和存储服务的大型基础设施, 它由服务器、存储器和网络

交换机组等IT设备构成,同时还配备了制冷设备保持机房恒温恒湿。数据中心内各项设备的全天候运行造成了巨大的能耗^[1],但提供计算服务的服务器群中约15%的服务器却处于空闲状态,而处于忙碌状态的服务器中约75%其CPU使用率不足20%^[2]。为了构建绿色节能的数据中心,高能耗低能效问题正受到广泛的关注与研究。现有的研究工作大多从提高能效的角度出发,设计服务器群的任务流调度算法^[3-4],对运行在服务器群上的用户任务做负载均衡,从而充分利用每台服务器的计算资源。

服务器能耗数据的获取有两种途径:(1)获得云数据中心服务提供商的授权,通过该途径可以获得真实场景下的服务器各项性能指标和能耗数据,但研究人员很难获得相关授权且研究成果中也不能泄漏数据集的详细信息。(2)搭建仿真环境模拟数据中心内服务器的运行状态,宋杰等^[5]在单机环境中采集了与CPU相关的指标和能耗数据,并建立了CPU与服务器能耗之间的计算关系,但单机环境并不能体现客户端与数据中心内服务器的交互关系,而且CPU也不能反映网络、内存和磁盘等其他类型指标对能耗的影响;Li等^[6]搭建了仿真环境,采集数据后使用自动编码器对服务器能耗建立了预测模型,但搭建仿真环境的细节并没有表述清楚,并且只选用了World Cup 98^[7]和Clark net^[8]网络请求日志模拟网络I/O密集型任务,而没有考虑对CPU密集型任务的模拟。

特征选择是机器学习中至关重要的预处理步骤,用于剔除不相关特征以降低数据维度和建模复杂度。传统的特征选择有^[9]:过滤式(Filter)、包裹式(Wrapper)和嵌入式(Embedding)。由于过滤式不依赖于特定模型并且处理速度较快,因此在实际问题中更为常用。为获得具有可解释性的特征分析,基于因果关系的特征选择受到了越来越多的关注。因果特征选择以因果马尔科夫假设为基础,将原始特征空间构建成贝叶斯网络,在该网络中借助条件独立性测试寻找目标变量的马尔可夫边界,以此剔除冗余特征、构建因果特征子集^[10]。因果特征选择常用于肺癌^[11]等疾病的诊断与分析,为医疗人员溯源病因提供帮助。现有的很多研究工作针对服务器能耗进行了特征分析,Meisner等^[12]认为能耗由CPU主导;Economou等^[13]进一步考虑到内存和网络对能耗的影响;Davis等^[14]总结前人的研究工作后提出了一套通用的能耗特征集合,并验证了该集合的有效性。但这些静态的特征分析无法反映用户任务的动态变化,也不能捕捉到用户任务的特点。

随着机器学习的兴起,时序预测领域内的最新研究工作都借助机器学习模型对多元时间序列进行建模预测。Galicia等^[15-16]基于Spark框架和决策树(Decision tree, DT)提出了一种针对多元时间序列的建模流程。Bai等^[17]深入对比了卷积神经网络(Convolution neural network, CNN)和循环神经网络(Recurrent neural network, RNN)在序列建模任务上的性能,并提出了能捕捉更长历史模式的时序卷积网络(Temporal convolution network, TCN)。

目前服务器能耗数据领域仍存在以下3个问题:

(1)为了提高数据中心能效的同时保证用户任务的完成,任务流调度算法的设计依赖于用户任务的特征分析与服务器未来能耗的预测结果,因此若能捕捉到用户任务的特点并提供准确的能耗预测结果将有助于提高任务流调度算法的优越性。

(2)由于涉及公司商业机密与用户个人隐私,国内外的云数据中心服务提供商不会公开服务器的各项性能指标和能耗数据,相对应的用户任务也不会透露,因此没有公开的服务器能耗数据集供研究人员使用。

(3)不同类型的用户任务会使不同的服务器性能指标成为关键特征,例如CPU密集型任务和网络I/O密集型任务的关键特征就有很大的不同。但现有的过滤式特征选择构建的特征子集内会存在冗余特征,这些冗余特征无法反映用户任务的特点,会对运维人员判断用户任务类型产生误导,因此过滤式特征选择不能满足运维人员的需求。

针对上述问题,本文首先提出了一套模拟数据中心内服务器运行情况的仿真环境架构;随后基于该架构,本文以FFmpeg和World Cup 98两种Benchmark为例,分别模拟CPU密集型和网络I/O密集型

任务采集服务器能耗数据集;最后本文将基于因果关系的特征选择应用到能耗数据的特征分析中,并与过滤式特征选择进行了对比实验,这是因果特征选择首次应用于能耗数据的特征分析中。实验结果表明,因果特征在75%的情况下取得了最优的预测精度,同时其特征子集大小约为过滤式特征子集大小的1/3到1/6。结合具体的用户任务来看,因果特征子集排除了冗余特征,只保留了最能体现用户任务特点的特征,为运维人员设计服务器群的任务流调度算法提供了具有可解释性的依据和指导。

1 特征选择

1.1 过滤式特征选择

过滤式特征选择将特征与目标变量间的关系分为强相关、弱相关和不相关,并旨在挑选强相关特征^[18],衡量特征间相关性的统计指标一般选用皮尔逊相关系数(Pearson correlation coefficient)或斯皮尔曼等级相关系数(Spearman's rank correlation coefficient),它们的取值范围在 $[-1, 1]$ 内,其中“-1”表示 X 和 Y 完全负相关,“0”表示 X 和 Y 完全不相关,“1”表示 X 和 Y 完全正相关。皮尔逊相关系数用于衡量变量间的线性关系,其数学描述如下

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (1)$$

式中: $\text{Cov}(X, Y)$ 为 X 和 Y 的协方差, σ_X 和 σ_Y 分别为 X 和 Y 的标准差。斯皮尔曼等级相关系数衡量地是变量间的单调关系,其数学描述如下

$$\rho_{X,Y} = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2 \sum_i (y_i - \bar{y})^2}} \quad (2)$$

1.2 基于因果关系的特征选择

尽管过滤式构建的特征子集与目标变量间具有强相关性,但特征子集内会存在冗余性,即多个特征组合后会蕴含其他特征的信息从而使得其他特征成为冗余特征。冗余特征的存在会在一定程度上误导运维人员对当前用户任务类型的判断。而基于因果关系的特征选择旨在构建与目标变量强相关且非冗余的特征子集,它以因果马尔可夫假设为理论基础,借助于条件独立性测试,搜索目标变量在贝叶斯网中的马尔可夫边界,从而构建出具有可解释性的特征子集^[19]。根据因果关系可以将特征进一步细分为4种类型:强相关特征、非冗余特征、冗余特征和不相关特征,图1展示了这4类特征间的关系。

Hiton-PC:寻找目标变量的直接父子结点。

输入:训练数据集、目标变量。

输出:目标变量的直接父子结点集合。

(1)初始化目标变量的直接父子结点集合为空集;

(2)重复步骤(3,4)直至特征空间内没有与目标变量相关的特征;

(3)将特征空间中与目标变量相关性最高的特征加入直接父子结点集合,并从特征空间内移除该特征;

(4)检验直接父子结点集合内是否存在冗余特征,若存在则移除冗余特征;

(5)返回目标变量的直接父子结点集合。

根据因果马尔可夫假设,将能耗数据集的特征空间构建成贝叶斯网络后,对服务器能耗有决定性




图1 特征类型及其关系

Fig.1 Feature types and their relationship

作用的特征在网络中表现为能耗的直接父结点与直接子结点,直接父结点是直接导致能耗变化的特征,而直接子结点是因能耗变化而立即变化的特征。因此本文应用了因果特征选择算法 Hiton^[20]的一部分,即 Hiton-PC 算法,过程如前文所示。本文利用 Hiton-PC 算法寻找服务器能耗的直接父子结点,从而构建出具有可解释性的因果特征子集。

2 仿真环境搭建与数据采集

表 1 服务器配置信息

Table 1 Server configuration information

服务器角色	CPU	内存/GB
服务端	Intel Core i7-8700K@3.7 GHz	16
客户端	Intel Core i3-3240@3.4 GHz	4
监控端	Intel Xeon ES-2609@2.4 GHz	8

2.1 仿真环境的硬件和软件配置

本文提出的仿真环境中,硬件设备包括 3 台服务器、1 台路由器和 1 件电源分配单元(Power distribution unit, PDU)。3 台服务器分别作为服务端、客户端和监控端,详细配置如表 1 所示。服务端模拟数据中心内提供计算资源的服务器,客户端模拟向数据中心请求服务的用户电脑,监控端模拟数据中心内负责监控并存储数据的服务器。路由器负责构建服务器之间的通信网络,PDU 负责给服务端供电。软件配置方面,所有服务器的操作系统均为 CentOS,服务端配置了 collectd,监控端配置了 OpenTSDB。collectd 是 Unix 守护程序,用于收集并传输服务器的性能指标,通过内置的不同探针可以采集到 CPU、内存、磁盘等类型的指标。OpenTSDB 是基于 Hbase 实现的分布式时序数据库,与关系型数据库不同,OpenTSDB 根据时间戳存储数据。

2.2 FFmpeg 和 World Cup 98 任务简介

数据中心内服务器通过网络与用户进行交互并向用户提供计算服务和存储资源,因此本文选择 FFmpeg 和 World Cup 98 两种 Benchmark 分别模拟 CPU 密集型和网络 I/O 密集型任务,以此模拟数据中心内服务器的运行状态。FFmpeg 是用于处理音视频的程序,它对 CPU 的占用率较高,本文在服务端持续运行该程序来模拟 CPU 密集型任务。World Cup 98 是 1998 年世界杯官网的 Web 请求日志,根据该日志,本文通过客户端向服务端发送 Web 请求,服务端解析并处理请求后将结果返回给客户端来模拟网络 I/O 密集型任务。

2.3 仿真环境架构和数据采集流程

本文提出的仿真环境架构如图 2 所示,3 台服务器通过以太网线直连到路由器上,服务端的电源线连接到 PDU 上,由 PDU 给服务端供电,PDU 通过串行线连接到监控端。具体的数据采集流程如下所述:

(1) 客户端发起 Web 请求,请求服务端运行 FFmpeg 或 World Cup 98 以模拟 CPU 密集型或网络 I/O 密集型任务。

(2) 路由器将用户请求转发到服务端。

(3) 服务端接收到用户请求后,执行用户任务。在服务端运行期间,collectd 采集服务端的各项性能指标,如 CPU 空闲时间、网络传输报文总数、系统已使用的物理 RAM 量等,并将这些数据定期发送给路由器。

(4) 路由器收到 collectd 采集的数据后转发给监控端内的 OpenTSDB 进行存储。

(5) PDU 给服务端供电,监控端内的自定义能耗采集脚本通过串行线定期读取 PDU 的能耗数据,并存储在 OpenTSDB 中。

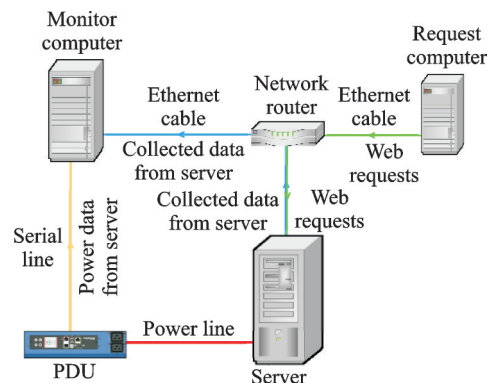


图 2 仿真环境架构

Fig.2 Architecture of simulation environment

2.4 数据采集与预处理

由于数据中心内服务器的主要职责是提供计算存储资源和网络通信,因此本文选定CPU、内存、磁盘、网络和进程这5种类型的服务器指标作为特征,这些特征的命名方式及物理意义如表2所示,其他各类型中断处理的指标由于比较琐碎,因此没有在表2中记录。

表2 特征命名及物理意义

Table 2 Feature naming and physical meaning

特征类别	特征命名	物理意义
CPU	cpu-i-system	第 <i>i</i> 核CPU处于内核态的时间
	cpu-i-nice	第 <i>i</i> 核CPU处理用户进程的时间
	cpu-i-steal	第 <i>i</i> 核CPU处于非自愿等待状态的时间
	cpu-i-softirq	第 <i>i</i> 核CPU处理软中断的时间
	cpu-i-idle	第 <i>i</i> 核CPU空闲的时间
	cpu-i-user	第 <i>i</i> 核CPU处理内部用户进程的时间
	cpu-i-wait	第 <i>i</i> 核CPU等待IO操作的时间
	cpu-i-interrupt	第 <i>i</i> 核CPU处理硬中断的时间
内存	memory-free	系统未使用的物理RAM量
	memory-used	系统已使用的物理RAM量
	memory-cached	系统高速缓存使用的物理RAM量
	memory-buffered	原始磁盘块的临时存储量
	memory-slab_recl	Slab可回收的RAM量
	memory-slab_unrecl	Slab不可回收的RAM量
磁盘	disk-i-ops_read	第 <i>i</i> 块磁盘的读操作数
	disk-i-ops_write	第 <i>i</i> 块磁盘的写操作数
	disk-i-time_read	第 <i>i</i> 块磁盘的读操作完成的平均时间
	disk-i-time_write	第 <i>i</i> 块磁盘的写操作完成的平均时间
	disk-i-merged_read	第 <i>i</i> 块磁盘的可以合并的读操作数
	disk-i-merged_write	第 <i>i</i> 块磁盘的可以合并的写操作数
	disk-i-octets_read	第 <i>i</i> 块磁盘的读操作8位字节数
	disk-i-octets_write	第 <i>i</i> 块磁盘的写操作8位字节数
	disk-i-io_time	第 <i>i</i> 块磁盘的读写时间
disk-i-weighted_io_time	第 <i>i</i> 块磁盘的加权读写时间	
disk-i-pending	第 <i>i</i> 块磁盘的未完成读写操作数	
网络	if-eth-errors-rx	通过以太网收到的错误包总数
	if-eth-errors-tx	通过以太网传输的错误包总数
	if-eth-octets-rx	通过以太网收到的字节总数
	if-eth-octets-tx	通过以太网传输的字节总数
	if-eth-packets-rx	通过以太网收到的报文总数
	if-eth-packets-tx	通过以太网传输的报文总数
进程	ps-fork_rate	自重新启动以来创建的进程数
	ps-state_running	处于运行状态的进程数
	ps-state_sleeping	处于睡眠状态的进程数
	ps-state_stopped	处于停止状态的进程数
	ps-state_blocked	处于阻塞状态的进程数
	ps-state_paging	处于分页状态的进程数
	ps-state_zombies	处于僵尸状态下的进程数
能耗	power	服务器能耗

基于本文提出的仿真环境架构和数据采集流程,本文设置 collectd 和自定义能耗采集脚本的采集频率均为 1 s,根据表 2 列出的指标和其他琐碎指标构建了共 159 个特征,得到的原始数据集统计信息如表 3 所示,其中 ffmpeg 是使用 FFmpeg 模拟 CPU 密集型任务得到的数据集,wc98-44 和 wc98-67 分别是使用 World Cup 98 第 7 周和第 10 周日志模拟网络 I/O 密集型任务得到的数据集。

由于数据采集过程中存在白噪声并且预测下一秒的能耗值不能提供充足的信息给运维人员,因此本文对原始数据集进行了窗口大小为 60 s 的不重叠平均平滑操作,处理后的数据集统计信息如表 4 所示。本文将对处理后的数据集进行特征分析与对比实验。

3 实验与分析

3.1 问题定义

由于数据中心内服务器的各项性能指标与能耗数据是按时间顺序采集,因此能耗预测归属于多元时间序列预测问题。结合时序预测问题的定义^[21],本文给出能耗预测问题的数学描述:以 $z_t \in \mathbf{R}^N$ 表示 t 时刻采集到的服务器 N 项指标(包括能耗值), $z_t[i] \in \mathbf{R}$ 表示 t 时刻采集到的服务器第 i 项指标,给定长度为 P 的历史数据序列 $X = \{z_{t_1}, z_{t_2}, \dots, z_{t_p}\}$,目标是预测下一时间戳的能耗值 $Y = \{z_{t_{p+1}}[\text{power}]\}$ 。

实验有两个目的:(1)结合具体用户任务,与过滤式特征子集进行对比,验证因果特征子集的合理性;(2)结合具体时序预测模型,分别使用过滤式和基于因果关系的特征子集进行训练和测试,验证因果特征子集的有效性。

3.2 实验设置

特征选择方面:首先,由于数据集和时序相关,因此训练集和测试集是由处理后的数据集按时间顺序以 8:2 的比例划分而来。其次,根据训练集剔除训练集和测试集中方差为 0 的常量特征。最后,使用皮尔逊相关系数、斯皮尔曼等级相关系数和 Hiton-PC 算法进行特征选择,本文设定阈值为 0.8,若某特征和能耗间的皮尔逊相关系数或斯皮尔曼等级相关系数的绝对值大于等于该阈值,则该特征与能耗是强相关的,Hiton-PC 算法中用于搜索冗余特征的条件特征子集大小设置为 3。

时序预测方面:结合本文 3.1 节对于能耗预测问题的定义,本文设定时序预测的目标是根据前 10 min 的历史数据预测后 1 min 的能耗,即给定长度为 10 的历史数据序列 $X = \{z_{t_{\lambda+1}}, z_{t_{\lambda+2}}, \dots, z_{t_{\lambda+10}}\}$,目标是预测下一时间戳的能耗值 $Y = \{z_{t_{\lambda+11}}[\text{power}]\}$,其中 λ 是任意起始时间戳。

机器学习模型方面:本文选用 DT、随机森林(Random forest, RF)、长短期记忆网络(Long short-term memory network, LSTM)和时序卷积网络(Temporal convolution network, TCN)这 4 个常用于序列建模任务的模型,其中 DT 和 RF 使用 Sklearn^[22]实现,LSTM 和 TCN 使用 Pytorch^[23]实现,LSTM 和 TCN 以学习率 0.01 训练 300 次。为保证可复现性,所有模型的随机数种子设置为 7。

评价指标方面:本文选用平均绝对误差(Mean absolute error, MAE)和归一化均方根误差(Normalized root mean squared error, nRMSE)衡量模型的预测精度,以 y_i 表示第 i 个样本的能耗值, \hat{y}_i 表示预测

表 3 原始数据集统计信息

Table 3 Statistics of raw dataset

数据集	样本数	采样率/s	特征数
ffmpeg	71 341	1	159
wc98-44	204 317	1	159
wc98-67	158 159	1	159

表 4 处理后的数据集统计信息

Table 4 Statistics of processed dataset

数据集	样本数	采样率/min	特征数
ffmpeg	1 189	1	159
wc98-44	3 405	1	159
wc98-67	2 635	1	159

的能耗值, n 表示样本数, σ_y 表示 y 的标准差, 那么 MAE 和 nRMSE 的数学描述为

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (3)$$

$$\text{nRMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} / \sigma_y \quad (4)$$

3.3 实验结果及分析

表5展示了不同特征选择算法在3个数据集上构建的特征子集大小, 其中特征子集 Chaos 是根据 Davis 等^[14]提出的通用能耗特征集合构建。由表5可知, Hiton-PC 算法构建的因果特征子集最小, 约为过滤式特征子集大小的 1/3~1/6。由于条件特征子集大小为 3, 因此 Hiton-PC 算法的平均时间复杂度为 $O(|N| \cdot |\text{PC}|^3)$, N 为原始特征数, PC 为因果特征子集大小。

以 CPU 密集型任务为例, 表6列举了 Hiton-PC 算法在 ffmpeg 数据集上构建的因果特征子集, 其中 cpu-0-idle、cpu-2-idle 和 cpu-3-idle 分别表示第 0/2/3 核 CPU 的空闲时间, 第 i 核 CPU 的运行总时间记为 cpu- i -time, 而 CPU 的空闲时间与 CPU 的使用率紧密相关, 由于

$$\text{cpu}_i\text{-usage} = \left(1 - \frac{\text{cpu}_i\text{-idle}}{\text{cpu}_i\text{-time}}\right) \times 100\% \quad (5)$$

数据集 ffmpeg 的因果特征子集说明有 3 核 CPU 参与执行了该项用户任务, 反映出该项任务对于 CPU 的占用率较高, 并且 ps-state_stopped 反映了处于停止状态的进程产生了很多能耗。结合先验知识, 由于数据集 ffmpeg 是在服务端持续运行 FFmpeg 模拟 CPU 密集型任务采集得到, 显然 CPU 会产生大量能耗; 此外, 由于 FFmpeg 的不间断运行会导致系统内其他任务的挂起, 服务端为了记录这些挂起任务的必要信息也会耗费大量能源, 因此 Hiton-PC 算法构建的因果特征子集是合理的, 并且充分反映出用户任务的特点。而过滤式特征子集内除了上述 5 个特征外, 还包含了诸如 cpu-0-nice、cpu-0-user 和 cpu-2-nice 等 20 多个冗余特征; 通用的能耗特征集合 Chaos 是以服务器为最小单位构建的, 无法区分不同的用户任务, 因此同样存在冗余特征。

表7记录了 4 个模型在 3 个数据集上分别使用 5 个特征子集训练后在测试集上的预测精度。总体来看, 使用因果特征子集训练的模型在 75% 的情况下取得了最优预测精度, 在另外 25% 的情况下其预测精度也在可接受的范围内。结合表5分析, 尽管因果特征子集大小远小于过滤式特征子集大小, 但预测精度不减反增, 这表明因果特征子集是有效的, 不仅大大缩减了特征子集规模, 而且尽可能保留了有效信息。

结合 wc98-67 数据集具体分析, 图3~7是使用不同特征子集训练 LSTM 的拟合曲线。在能耗曲线前半段, 5 个特征子集的拟合效果相似。在能耗曲线后半段, 能耗开始陡然攀升时, 只有因果特征子集较为贴切地跟随真实曲线变化, 而其他特征子集则完全脱离了真实曲线的攀升路径。这是因为冗余特征在一定程度上干扰了模型, 特别是在能耗发生突变时, 这些干扰就会导致预测结果的不稳定。图8是对应的损失曲线, 可以发现因果特征子集很快收敛, 这也得益于因果特征子集剔除了较多的冗余特征。

表5 特征子集大小

Table 5 Size of feature subset

数据集	Pearson	Spearman	Chaos	Hiton-PC
ffmpeg	25	28	15	5
wc98-44	33	35	15	6
wc98-67	30	25	15	5

表6 ffmpeg 的因果特征子集

Table 6 Causal feature subset of ffmpeg data set

特征名称	物理意义
cpu-0-idle	第 0 核 CPU 空闲的时间
cpu-2-idle	第 2 核 CPU 空闲的时间
cpu-3-idle	第 3 核 CPU 空闲的时间
ps_state-stopped	处于停止状态的进程数
power	服务器能耗

表7 模型预测结果
Table 7 Model forecast results

Method	Metric	ffmpeg				wc98-44				wc98-67			
		DT	RF	LSTM	TCN	DT	RF	LSTM	TCN	DT	RF	LSTM	TCN
All	MAE	6.035	4.352	15.44	48.98	0.995	0.727	0.794	33.71	1.438	1.021	1.335	31.67
	nRMSE	0.672*	0.478	1.431	3.372	0.479	0.354	0.389	12.21	0.912	0.659	0.901	11.43
Pearson	MAE	6.141	4.297	4.650	48.98	0.960	0.738	0.728	0.937	1.286	1.026	0.969	31.67
	nRMSE	0.741	0.487	0.504	3.372	0.471	0.360	0.359*	0.521*	0.844	0.671	0.615	11.43
Spearman	MAE	5.879	4.228	4.476	12.43	0.971	0.741	0.742	2.142	1.303	1.008	1.218	31.67
	nRMSE	0.723	0.517	0.537	1.011	0.476	0.360	0.371	1.003	0.892	0.663	0.901	11.43
Chaos	MAE	6.641	4.389	5.880	11.781	0.994	0.689	0.780	2.169	1.410	1.099	0.908	3.090
	nRMSE	0.733	0.456	0.709	1.058	0.482	0.341	0.384	1.008	0.947	0.763	0.531	1.222
Hiton-PC	MAE	6.498	3.971	4.385	5.511	0.923	0.681	0.756	2.130	1.022	0.818	0.691	0.689
	nRMSE	0.751	0.415**	0.461*	0.554*	0.455*	0.338**	0.379	1.001	0.516*	0.440*	0.331**	0.344*

注:*表示某列最优的nRMSE,**表示某数据集上最优的nRMSE。




图3 基于所有特征的拟合曲线
Fig.3 Fitting curves based on all features




图4 基于皮尔逊系数特征的拟合曲线
Fig.4 Fitting curves based on Pearson features

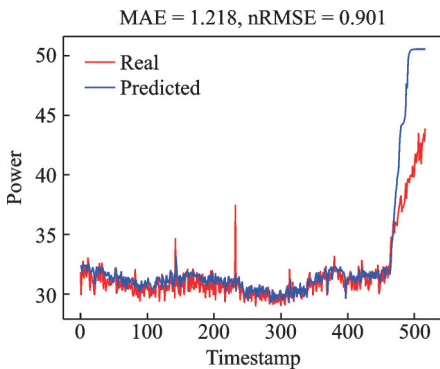


图5 基于斯皮尔曼系数特征的拟合曲线
Fig.5 Fitting curves based on Spearman features




图6 基于Chaos特征的拟合曲线
Fig.6 Fitting curves based on Chaos features

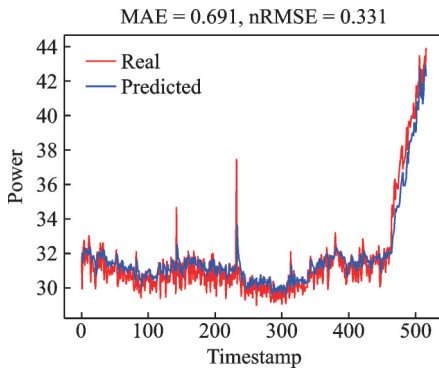


图7 基于Hiton-PC特征的拟合曲线

Fig.7 Fitting curves based on Hiton-PC features

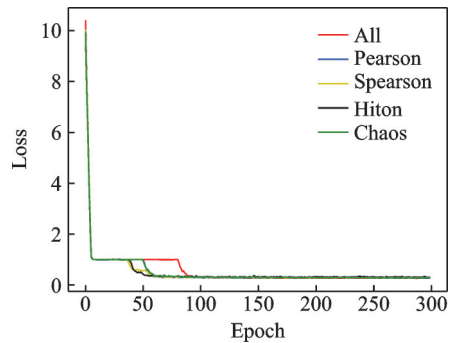


图8 LSTM在wc98-67数据集上的损失曲线

Fig.8 Loss curves of LSTM on wc98-67 data set

4 结束语

数据中心的高能耗低能效问题亟待解决,为了给运维人员设计任务流调度算法提供帮助,本文提出了一套模拟数据中心内服务器运行状态的仿真环境架构,并将因果特征选择应用到特征分析中,最后通过对比实验论证了因果特征选择有更稳定的效果。

在用户任务固定的静态场景下,因果特征选择能很好地捕捉到用户任务的特点,但为了经济效益最大化,云数据中心服务提供商会将同一台服务器出售给多个用户分时使用,如何在特征漂移的动态数据流场景下进行因果特征选择是本文未来的研究方向。

参考文献:

- [1] DAYARATHNA M, WEN Y, FAN R. Data center energy consumption modeling: A survey[J]. *IEEE Communications Surveys and Tutorials*, 2015, 18(1): 732-794.
- [2] SHEN Z, ZHANG X, XIA B, et al. Multi-granularity power prediction for data center operations via long short-term memory network[C]//*Proceedings of 2019 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Big Data & Cloud Computing, Sustainable Computing & Communications, Social Computing & Networking (ISPA/BDCLOUD/SocialCom/SustainCom)*. [S.l.]: IEEE, 2019: 194-201.
- [3] VON LASZEWSKI G, WANG L, YOUNGE A J, et al. Power-aware scheduling of virtual machines in DVFS-enabled clusters[C]//*Proceedings of 2009 IEEE International Conference on Cluster Computing and Workshops*. [S.l.]: IEEE, 2009: 1-10.
- [4] MEI J, LI K, LI K. Energy-aware task scheduling in heterogeneous computing environments[J]. *Cluster Computing*, 2014, 17(2): 537-550.
- [5] 宋杰, 李甜甜, 闫振兴, 等. 一种云计算环境下的能效模型和度量方法[J]. *软件学报*, 2012, 23(2): 200-214.
SONG Jie, LI Tiantian, YAN Zhenxing, et al. Energy-efficiency model and measuring approach for cloud computing[J]. *Journal of Software*, 2012, 23(2): 200-214.
- [6] LI Y, HU H, WEN Y, et al. Learning-based power prediction for data centre operations via deep neural networks[C]//*Proceedings of the 5th International Workshop on Energy Efficient Data Centres*. New York, USA: ACM, 2016: 1-10.
- [7] ARLITT M, JIN T. 1998 world cup web site access logs[EB/OL].(1998-07-12) [1998-07-12]. <ftp://ita.ee.lbl.gov/html/contrib/WorldCup.html>.
- [8] ARLITT M F, WILLIAMSON C L. Web server workload characterization: The search for invariants[J]. *ACM Sigmetrics Performance Evaluation Review*, 1996, 24(1): 126-137.
- [9] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016.
- [10] YU K, GUO X, LIU L, et al. Causality-based feature selection: Methods and evaluations[J]. *ACM Computing Surveys*

- (CSUR), 2020, 53(5): 1-36.
- [11] HONG Z, YANG J. Optimal discriminant plane for a small number of samples and design method of classifier on the plane[J]. Pattern Recognition, 1991, 24(4): 317-324.
- [12] MEISNER D, WENISCH T F. Peak power modeling for data center servers with switched-mode power supplies[C]//Proceedings of the 16th ACM/IEEE International Symposium on Low Power Electronics and Design. New York, USA: ACM, 2010: 319-324.
- [13] ECONOMOU D, RIVOIRE S, KOZYRAKIS C, et al. Full-system power analysis and modeling for server environments [C]//Proceedings of International Symposium on Computer Architecture. [S.l.]: IEEE, 2006.
- [14] DAVIS J D, RIVOIRE S, GOLDSZMIDT M, et al. Chaos: Composable highly accurate os-based power models[C]// Proceedings of 2012 IEEE International Symposium on Workload Characterization (IISWC). [S.l.]: IEEE, 2012: 153-163.
- [15] GALICIA A, TORRES J, MARTÍNEZ-ÁLVAREZ F, et al. A novel Spark-based multi-step forecasting algorithm for big data time series[J]. Information Sciences, 2018, 467: 800-818.
- [16] GALICIA A, TALAVERA-LLAMES R, TRONCOSO A, et al. Multi-step forecasting for big data time series based on ensemble learning[J]. Knowledge-Based Systems, 2018, 163: 830-841.
- [17] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-03-03) [2018-04-19]. <https://arxiv.org/abs/1803.01271>.
- [18] 余奎. 流特征下的在线知识发现研究[D]. 合肥:合肥工业大学, 2013.
- [19] TSAMARDINOS I, ALIFERIS C F. Towards principled feature selection: Relevancy, filters and wrappers[C]//Proceedings of International Workshop on Artificial Intelligence and Statistics. Florida, USA: Society for Artificial Intelligence and Statistics, 2003: 300-307.
- [20] ALIFERIS C, TSAMARDINOS I, STATNIKOV A. Hiton: A novel Markov blanket algorithm for optimal variable selection [C]//Proceedings of AMIA. Washington, USA: [s.n.], 2003: 21-25.
- [21] BROCKWELL P J, BROCKWELL P J, DAVIS R A, et al. Introduction to time series and forecasting[M]. [S.l.]: Springer, 2016.
- [22] SWAMI A, JAIN R. Scikit-learn: Machine learning in Python[J]. Journal of Machine Learning Research, 2013, 12(10): 2825-2830.
- [23] PASZKE A, GROSS S, MASSA F, et al. Pytorch: An imperative style, high-performance deep learning library[J]. Advances in Neural Information Processing Systems, 2019, 32: 8026-8037.

作者简介:



周清(1997-),男,硕士研究生,研究方向:特征选择、时序预测。



张譔晟(1996-),男,硕士研究生,研究方向:机器学习、时序预测。



沈子钰(1995-),女,博士研究生,研究方向:机器学习、时序预测。



李云(1974-),通信作者,男,教授,博士生导师,研究方向:机器学习、模式识别等,E-mail:liyun@njupt.edu.cn。

(编辑:张彤)