

基于长短期记忆网络 (LSTM) 的 数据中心温度预测算法

徐一轩, 伍卫国, 王思敏, 胡 壮, 崔 舜
(西安交通大学 电子与信息工程学院, 陕西 西安 710049)

摘 要:大数据和云计算时代推动数据中心规模迅速扩大,有调研研究显示,国内数据中心年耗电量超过全社会用电量的1.5%,且在数据中心运行时高达10%的机柜运行温度高于设备可靠性的允许范围。温度监测和预测对于防止服务器过热而停机和提高数据中心的能源效率至关重要。文中提出了一种基于长短期记忆网络 (LSTM) 的温度预测算法,该算法使用数据中心温度监控数据和服务器实际运行参数生成时间序列训练集来训练神经网络模型并预测服务器入口温度。为了降低预测模型的训练时间,基于热局部性原理提出了一种联合建模框架,显著降低了在线温度预测建模的复杂性。在一个有15台服务器的测试台上进行了实验验证,结果表明该方法可以准确地预测动态工作负载的服务器的入口温度演变。

关键词:数据中心;温度预测;长短期记忆网络;服务器入口温度

中图分类号:TP308

文献标识码:A

文章编号:1673-629X(2019)12-0001-07

doi:10.3969/j.issn.1673-629X.2019.12.001

Data Center Temperature Prediction Algorithm Based on Long Short-term Memory Network

XU Yi-xuan, WU Wei-guo, WANG Si-min, HU Zhuang, CUI Shun
(School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Nowadays, data center has been expanded dramatically by the development of big data and cloud computing. A survey has showed that annual power consumption of data centers in China exceeds 1.5% of the whole society consumption, furthermore, up to 10% of the rack operating temperature is higher than the allowable range of equipment reliability. Temperature monitoring and prediction are crucial for preventing server failures caused by overheating and improving energy efficiency in the data center. We propose a temperature prediction algorithm base on long short-term memory (LSTM) network. In this algorithm, we train the neural network model with temperature monitoring data and time series set composed of parameters of actual runtime and finally obtain the predicted temperature of the server entrance. In order to reduce the training time of the prediction model, we propose a joint modeling framework based on the thermal locality principle, which significantly reduces the complexity of online temperature prediction modeling. The experimental verification on a test bed with 15 servers shows that the proposed method can accurately predict the inlet temperature evolution of servers with dynamic workloads.

Key words: data center; temperature prediction; long short-term memory; server inlet temperature

0 引言

在数据中心长期运营成本中,其能耗成本所占比例为50%左右。而在所有的能耗成本中,制冷设备的能耗所占比例约为40%。随着对提高数据中心效率的需求的不断增加,降低能耗成本的需求迫在眉睫。目前数据中心常见的冷却系统是水冷和风冷,水冷系

统在散热性能上优于风冷,但是存在着技术要求和安全性性能上的不足,因此风冷仍旧是主要的数据中心冷却系统。文中的温度预测方法即是针对数据中心风冷系统。现代数据中心采用的节能方法包括动态调控机房空调(computer room air conditioner, CRAC)温度设定、改善风扇电机的转速^[1-2]、均衡出口温度^[3-5]等来

收稿日期:2018-12-11

修回日期:2019-04-15

网络出版时间:2019-06-27

基金项目:国家重点研发计划(2017YFB1001701);国家自然科学基金(61672423);河南省交通运输科技计划项目(2019J-2-5)

作者简介:徐一轩(1995-),男,硕士研究生,研究方向为高性能计算、机器学习;伍卫国,教授,博导,研究方向为高性能计算。

网络出版地址:http://kns.cnki.net/kcms/detail/61.1450.TP.20190627.1102.036.html

提高制冷设备散热效率,以及使用虚拟机整合工作负载^[6]提高服务器能耗效率。但是,由于这种积极的优化,数据中心运营的安全空间越来越小。这个问题会随着更大的整合和密度的增加而进一步恶化^[7]。例如,流行的“刀片”系统在同样的体积中包含更多的计算,在几年内将热量密度提高了七倍。这个趋势要求数据中心的监控从被动到主动,通过温度预测,服务器可以及早预测潜在的过热事件,给操作员足够的时间做出反应。

文中介绍了目前数据中心温度预测的相关工作,讨论了长短期记忆网络在数据中心温度预测方面的优势,同时提出了一种联合建模框架,并通过实验进行了验证。

1 相关工作

目前,数据中心的温度预测算法主要分为两类。第一类是基于热力学的解决方案,使用基本的热力学定律和数据中心布局来推导数据中心内不同位置的物理热力学模型^[8]。文献[9]将计算流体力学(CFD)模型进行抽象和简化,牺牲一定的精确度来提高速度,该模型用矩阵表示各机柜温度对服务器入口温度的影响系数,以此来预测温度。文献[10]基于简化的热力学规律、CPU 温度、利用率和气流速度来仿真服务器的温度分布。文献[11]提出一种基于热力学的简化温度模型,模型参数通过机器学习得到。然而,基于热力学的温度预测模型依赖于气流动力学在具体机房的一些假设,模型固定且有针对性,不适用于推广到不同的数据中心环境。

第二类是以数据为驱动的解决方案,使用机器学习或数据挖掘的方法来建立预测模型。文献[12]提出了一种将云模型和 RBF 神经网络结合的新模型,用来预测数据中心温度。文献[13]采用人工神经网络来学习和预测静态工作量分配下的稳态温度分布,该方法依赖于稳态热模型,当服务器的负载动态变化时,它们不能很好地模拟温度演变。文献[14]集成了 CFD 建模、无线传感和实时数据驱动预测,模拟的温度分布和传感器测量值均用于训练实时预测算法,提出了线性预测模型。现有的数据为驱动的解决方案没有考虑到温度随时序渐变的特点,对于温度来说,温度增高或降低都是一个与时序有关的渐变过程,其变化趋势对于温度预测来说极为重要。即现有模型对于温度数据的时间序列相关性的处理能力存在不足,这一点导致在温度预测方面仍有缺陷。

针对以上两个问题,文中提出一种基于长短期记忆网络的实时温度预测模型。为了实现可扩展性,基于热量传导的局部性原理来建立模型,即服务器周围

的温度主要受其邻近服务器的配置影响,而距离远的服务器则对其影响不大,把这种特性称为热局部性原理。由于这种热局部特性,可以在服务器之间分配建模任务:每台服务器通过使用自身数据以及邻近服务器数据和传感器测量值来学习和模拟自身周围的温度。每个服务器建立自己的预测模型,模型的复杂性不会因为数据中心规模的扩大而增加。因此,算法在理论上可扩展到大型数据中心。文中采用以数据为中心的建模方法,从实时传感器数据和工作负载信息中训练人工神经网络模型。即使在服务器的开/关状态,工作负载,服务器组,空调设备维护等配置发生变化的情况下,也能够进行实时预测。为了实现更准确的预测,文中考虑了温度的时间序列相关性,采用对时间序列处理能力强的长短期记忆网络来建立温度预测模型。

2 基于长短期记忆神经网络的温度预测方法

2.1 基于神经网络的温度预测方法

由于大规模数据中心通常包含数以万计的服务器,多个 CRAC 单元和风扇,复杂的热交互和网络效应(例如,工作负载调度算法可能对温度分布产生很大影响),导致高精度的温度预测比较困难。根据前人的相关工作^[15],数据中心的温度预测可以分为条件温度预测和时序温度预测。

(1)条件温度预测。不从时序角度考虑,而考虑节点的状态和周围的环境等条件。文献[4]中描述了一种条件温度预测方法。将当前节点队列上最大能耗任务的能耗、所有任务的平均能耗和最近一段时间相邻节点温度的最大最小值作为神经网络的输入,输出是当前节点的峰值温度。用这样的数据训练出的神经网络能够预测一定条件下的服务器节点的峰值温度。这种方法能够预测数据中心的热点,针对热点问题,具有更高的准确性。

(2)时序温度预测。节点的温度以及运行数据都是随时间变化的。那么可以根据历史数据建立模型,预测一段时间以后节点的温度^[16]。从数据中心的历史数据中提取数据,输入主要有当前节点负载、当前节点温度以及周围可能影响节点温度的因素,输出是一段时间以后的入口温度。这里的时间间隔为预测视野,即模型要预测多长时间之后的温度。使用大量的数据能够训练出神经网络预测模型。训练出的模型能够从时序上建立输入与输出之间的关系,据此能够根据当前数据中心的实时数据计算得到一段时间以后节点的入口温度。这种方法还能被实时调用,随着数据中心的运行,可以用新的数据对网络进行更新并实时

预测。

2.2 时序温度预测与 LSTM

对于一般的数据中心而言,其任务量都是随时间呈周期性变化,任务量的变化是导致温度变化的主要原因。另外,在封闭的机房环境内,热量的产生与散热都是一个渐变的过程,这是选择时序预测的一个重要原因。

循环神经网络模型 (recurrent neural network, RNN)是处理时间序列数据比较好的选择,它用内部的隐含层节点状态来记忆任意长度的时序输入。近些年来,RNN 在自然语言处理、语音识别等领域取得了瞩目的成就。而长短期记忆网络 (long short - term memory ,LSTM) 预测模型是 RNN 的一个变型,对于处理时间序列上距离较远的节点比 RNN 表现好,RNN 在处理时间序列上间隔较长的相关节点时存在梯度爆炸或梯度消失的问题。与 BP 神经网络相比,LSTM 对处理与时间序列相关度高的数据有优势,BP 神经网络在相同的输入的情况下,输出是固定的,与输入序列关联较小,这就导致 BP 网络在预测温度时对温度趋势不敏感。与 RNN 相比,LSTM 在处理时间序列上距离较远的节点时有很大的优势。使用 LSTM 预测模型使得预测精度有了较大的提高。

3 联合建模框架

大型数据中心的规模大,且多采用分区间作业调度管理机制,采用统一建模方法作温度预测效果差。因此,文中提出了一种联合建模架构,依靠每台服务器来对自身的散热环境建模并进行预测。

联合建模体系结构利用了热量产生和传播的物理特性:热量局部扩散,遵循热流体动力学模型。尽管根据本地配置机架高度,服务器位置,服务器类型,开/关状态等,模型参数可能会有很大不同,但模型结构保持不变。联合架构还有一个优势就是模型学习和预测可以以分布式方式完成。每一台服务器使用自己的数据学习神经网络模型并进行预测,相互之间没有数据依赖,非常适合分布式计算。

影响服务器入口温度的因素有很多。首先是服务器自身的状态,包括服务器 CPU 利用率和 CPU 风扇转速,还有 CRAC 通风口处的空气流速和温度,此外,还有服务器入口附近各个点的温度。通常,一个点的温度主要受离其较近的热源的影响,而受距离远的热源的影响很小。所以,对于当前的服务器,假设其入口温度只受其邻近几个服务器的影响,忽略其他服务器的影响。在第 5 节,验证了邻近服务器温度对要建立预测模型的服务器入口温度的影响程度。确定了建立联合建模框架用当前服务器及其上下邻近的两个服务

器入口温度。这符合物理学规律,同时简化了问题。服务器节点之间相互影响关系如图 1 所示。

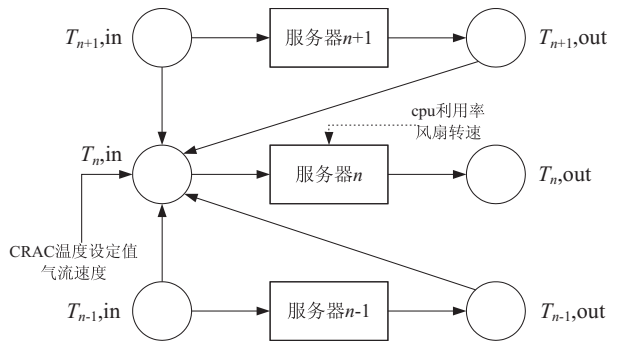


图 1 影响服务器节点入口温度的因素

综上所述,服务器 n 使用自己的入口和出口温度,其邻居 ($n-1$ 和 $n+1$) 的入口和出口温度,CRAC 通风口处的空气速度和温度,以及自己的 CPU 利用率和风扇转速来建立一个模型,计算一段时间以后自己的入口温度。

最终的联合建模框架如图 2 所示。每一个服务器节点使用实际运行数据训练自己的神经网络模型,最终得到整个数据中心的温度分布。

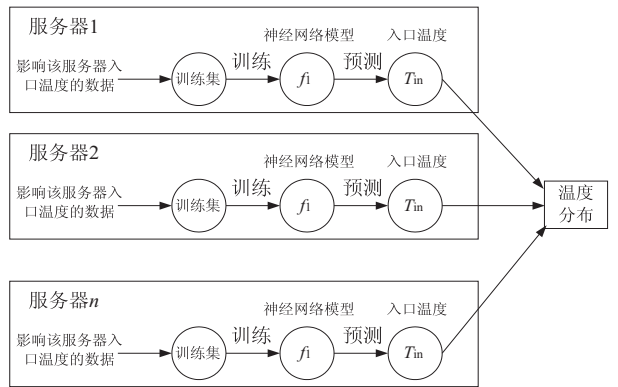


图 2 联合建模框架

4 神经网络的构建

4.1 数据集生成

训练神经网络的第一步就是生成数据集。表 1 是需要用到的变量名称及相应的符号。

表 1 变量名称与符号

| 变量名称 | 符号 |
|----------------|--------------|
| 服务器入口温度 | T_{in} |
| 服务器出口温度 | T_{out} |
| CPU 利用率 | α |
| 风扇转速 | φ |
| 上服务器入口温度 | $T_{+1,in}$ |
| 上服务器出口温度 | $T_{+1,out}$ |
| 下服务器入口温度 | $T_{-1,in}$ |
| 下服务器出口温度 | $T_{-1,out}$ |
| CRAC 通风口处的气流速度 | V_{fan} |
| CRAC 通风口处的温度 | T_{fan} |

收集数据中心温度监控数据和服务器实际运行参数,使用这些数据来生成数据集。每隔一段时间 s 收集一次数据,这些数据主要是影响服务器入口温度的因素,包括服务器入口和出口温度,其邻居 ($n-1$ 和 $n+1$) 的入口和出口温度,CRAC 通风口处的空气速度和温度,以及自己的 CPU 利用率和风扇转速。在时间点 t ,所有数据组成的向量用 $P(t)$ 表示:

$$P(t) = (T_{in}, T_{out}, \alpha, \varphi, T_{+1, in}, T_{+1, out}, T_{-1, in}, T_{-1, out}, v_{fan}, T_{fan})$$

LSTM 网络输入层是三维数据 [samples, time_steps, features]。其中 samples 表示训练样本数量;time_steps 表示时间步长,即每个数据与之前多少个时间序列的输入数据有关;features 表示特征值,即向量 $P(t)$ 。

使用最近的 R 个状态来预测 K 时间之后的服务器入口温度,即 time_steps = R , 预测视野 K 为时间间隔 s 的整数倍,设 $k = K/s$ 。也就是说,要使用时间点 t 及其最近的 R 个状态,来预测时间点 $t+k$ 的服务器入口温度。用 f_k 表示要求解的模型, $T_{t+k, in}$ 表示 $t+k$ 时刻服务器入口温度,预测行为可以表示为:

$$T_{t+k, in} = f_k(P(t-R+1), P(t-R+2), \dots, P(t-1), P(t))$$

f_k 函数的输入输出对即构成了需要的数据集的输入和输出。所以, $\langle (P(t-R+1), P(t-R+2), \dots, P(t-1), P(t)), T_{t+k, in} \rangle$ 构成一条网络输入输出数据对。

4.2 LSTM 神经网络结构

LSTM 是 RNN 一个的变形。RNN 是处理时间序列相关数据的最有效的工具,相比于其他神经网络, RNN 的输出层的结果不仅与当前输入有关而且与上一次隐含层结果有关,这就相当于对时间序列有了一定的记忆功能。LSTM 的出现解决了长期记忆的问题, LSTM 通过三个阀门作用在 RNN 的节点上来调节之前的网络记忆状态是否作用于当前网络的计算。图 3 是 LSTM 的结构示意,其中小圆圈表示加入的阀门。




图 3 LSTM 的结构示意

其中, X_n, Y_n 表示一次输入与输出, U, W, V 表示

权重, h_n 表示隐含层状态, h_n 不仅与 X_n 有关而且与前 R 个隐含层输出有关,若没有阀门控制则 h_n 可表示为 $f(UX_n + W_{n-1}S_{n-1} + W_{n-2}S_{n-2} + \dots + W_{n-R}S_{n-R})$,即实现了与前 R 个输入关联。但当 R 较大时,即当前输出与距离较远的输入有关联时,训练模型会随 R 增长呈指数增长。

三个门的作用为:遗忘门(forget gate)控制之前的隐含层状态 h_{n-1} 有多少保留到当前时刻 h_n ;输入门(input gate)控制当前时刻网络的输入 X_n 有多少保存到隐含层状态 h_n ;输出门(output gate)控制隐含层状态 h_n 有多少输出到当前时刻输出值 Y_n 。

三个控制阀门组成了 LSTM 的基本单元,称为 cell。图 4 是 LSTM 神经网络一个单元的基本结构,其中 f_n 表示遗忘门, i_n 表示输入门, o_n 表示输出门, h_n 表示当前单元状态。




图 4 LSTM 神经网络 cell 的基本结构

遗忘门 f_n 可表示为: $f_n = \delta(W_{f,x}X_n + W_{f,y}Y_{n-1} + b_f)$ 。

输入门 i_n 可表示为: $i_n = \delta(W_{i,x}X_n + W_{i,y}Y_{n-1} + b_i)$ 。

输出门 o_n 表示为: $o_n = \delta(W_{o,x}X_n + W_{o,y}Y_{n-1} + b_o)$ 。

当前单元输出: $h_n = h_{n-1}f_n + i_n \tanh(W_c X_n +$

$$U_c Y_{n-1} + b_c)$$

当前单元状态: $y_n = o_n \tanh(h_n)$ 。

其中 δ 表示 sigmoid 函数,作用于三个门上,其输出为 $[0, 1]$,每个值表示对应的部分信息是否应该通过。0 值表示不允许信息通过,1 值表示让所有信息通过。而 tanh 函数用在了状态和输出。 W 为权重,如 $W_{f,x}$ 为遗忘门对应的上一时态输出信息的权重, b 表示偏置。

在实现 LSTM 网络时,网络结构有以下重要参数需要设置:

Activation 即激活函数,默认设置为 'tanh'。Recurrent_activation 为循环步施加的激活函数,采用默

认函数设置'hard_sigmoid'。

Dropout 在深度学习网络中控制神经元按照一定概率舍弃,可以防止过拟合,一般认为设置为 0.5 时效果较好,文中设置为 0.2。

Timestep 在文中设置为 12,即每个数据与之前 12 个时间序列的输入数据相关联。

隐含层个数通常由经验参考方法设置,一般有两种参考值 $2N$ 和 $\log_2 N$, N 为输入层节点数。当隐含层节点数设置偏少时,网络的拟合效果会下降;设置偏多时,训练时间会延长,且易陷入局部极小点。文中最终设置隐含层节点数为 10。

Batch_size 表示一次训练的样本数目,该参数会影响到模型的优化程度和训练速度。一般来说,Batch_size 值越大,训练速度越快,即结果误差收敛越快,但是模型的泛化能力会降低。文中设置 Batch_size 为 128。

Epochs 表示迭代次数,即指使用所有样本完整训练的次数,设置 Loss Function(损失函数)为 MAE(平均绝对误差)表示训练结果误差,当 Loss 函数在收敛时即停止训练。

Optimizer 即优化器,设置优化器为 Adam 来计算更新步长。

最后计算预测数据与真实数据的均方根误差(RMSE)来衡量预测值和实际值之间的偏差。

5 实验结果与分析

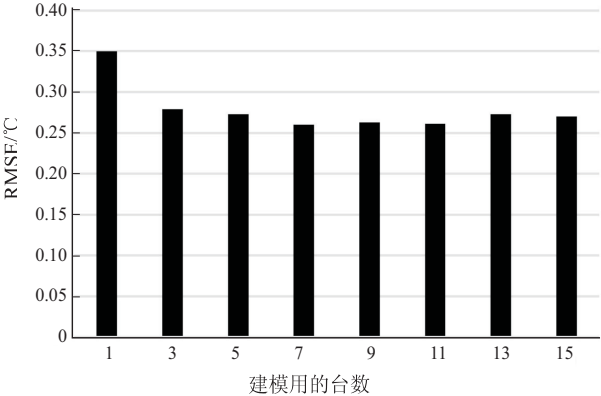
首先搭建一个小的实验环境来实现该预测算法,并且与文献[11]中提出的数据中心温度预测算法 ThermoCast 以及文献[14]中提出的温度预测算法进行对比。然后用文献[14]中一个包含 5 个服务器机架和 229 台服务器的高性能计算机中心(HPC)服务器机房的实验数据,实现该预测算法来验证算法的实际适用性。

在一个小的测试平台上进行实验。测试平台由 15 台服务器(型号:Dell PowerEdge 850)组成,放在一个机架上。机架放在一个小房间中,由泡沫板隔热。机架上方是一个排气口,用于将热空气排出房间。空调放置在房间外,空调和房间地板的进气口相连,将冷空气直接送到机架前面,这与流行的高架地板冷却设计的冷却气流一致。在每一个服务器的入口和出口处分别放置一个无线温度传感器(型号:TelosB Mote TPR2420CA)。在地板进风口放置一个温度传感器和气流速度传感器(型号:DegreeC F333)用来监测空调冷气风速和流速。

文中收集了测试数据中心 25 小时的运行数据,收集的数据时间间隔是 5 秒。使用其中 21 小时的数据

训练模型,剩下的 4 小时数据进行测试。数据是在服务器负载动态变化的情况下收集的。

首先验证并确定建立联合建模框架需要当前服务器的邻近服务器的具体数量。以其中一台服务器为例。图 5 展示了建立联合预测框架时用到当前及其邻近服务器台数与预测结果的均方根误差(RMSE)值的对比。基于 RMSE 和建模时间的综合考量,确定建立联合建模框架使用当前服务器及其上下 2 个邻近服务器的温度及运行数据。

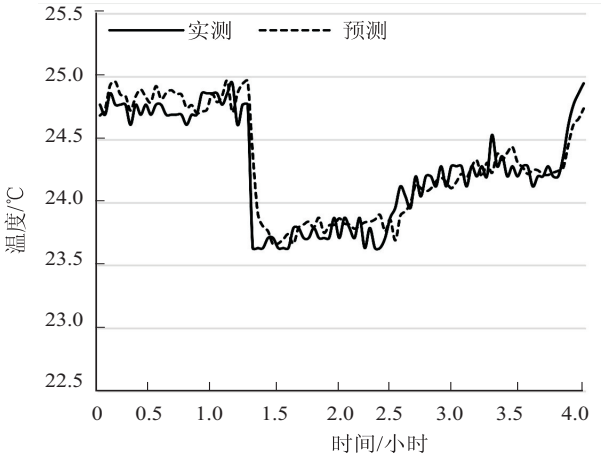


| 建模用的台数 | RMSE/°C |
|--------|---------|
| 1 | 0.35 |
| 3 | 0.28 |
| 5 | 0.27 |
| 7 | 0.26 |
| 9 | 0.26 |
| 11 | 0.26 |
| 13 | 0.27 |
| 15 | 0.27 |

图 5 选用台数对预测结果 RMSE 的影响

选取文献[11]中提出的数据中心温度预测算法 ThermoCast 作为对比。ThermoCast 算法基于简化的热力学规律构建温度预测模型,然后使用机器学习获取模型参数,在动态负载下的预测效果不错。预测模型的参数设置为 $R = 12$, $K = 600$ s,即预测 10 分钟后的温度分布。

图 6 和图 7 分别是服务器 8 和服务器 13 的入口温度预测结果(4 个小时内的观测结果)。从图中可以很明显看到,对于这三个服务器,文中预测算法能够较为精确地预测服务器入口温度。文中预测算法的 RMSE 值为 $0.27\text{ }^{\circ}\text{C}$,而 ThermoCast 算法的 RMSE 值约为 $0.33\text{ }^{\circ}\text{C}$ 。所以,相较于 ThermoCast 算法,文中提出的预测算法准确性更高。



| 时间/小时 | 实测温度/°C | 预测温度/°C |
|-------|---------|---------|
| 0.0 | 24.8 | 24.8 |
| 0.5 | 24.7 | 24.7 |
| 1.0 | 24.8 | 24.8 |
| 1.5 | 23.6 | 23.6 |
| 2.0 | 23.8 | 23.8 |
| 2.5 | 24.1 | 24.1 |
| 3.0 | 24.3 | 24.3 |
| 3.5 | 24.2 | 24.2 |
| 4.0 | 24.8 | 24.8 |

图 6 服务器 8 入口温度的预测结果




图 7 服务器 13 入口温度的预测结果

将文中提出的预测算法与文献[14]中提出的基于泰勒定理的线性数据中心温度预测模型进行比较。图 8 是文中预测算法在 $K = 600\text{ s}$ 和 $K = 300\text{ s}$ 时的服务器入口温度预测 RMSE 值。从图中可以看出,文中算法有很好的预测效果。实际上,当 $K = 600\text{ s}$ 和 $K = 300\text{ s}$,文中温度预测算法的 RMSE 值分别为 $0.27\text{ }^{\circ}\text{C}$ 和 $0.23\text{ }^{\circ}\text{C}$,而文献[14]的算法仅能保证 RMSE 低于 $0.5\text{ }^{\circ}\text{C}$ 。相比之下,文中算法的预测精确度有明显提升,且算法适应性较好,不会出现预测结果偏差较大的情形。

尝试用文献[14]在密歇根州立大学高性能计算机中心(HPCC)的服务器机房收集的实验数据来验证




图 8 文中预测算法在两种预测视野下的服务器入口温度预测的均方根误差

文中预测算法。文献[14]的实验数据来自 35 个温度传感器和 4 个气流速度传感器部署在五个服务器机架上的 229 台服务器。这些机架排列成两行,之间有冷通道,除了将地板冷却空气从地板砖吹入冷通道的高架地板冷却系统之外,还可以在每排机架之间安装两排行式空调冷却装置。其中 16 个传感器部署在一个机柜的前后监控服务器入口和出口温度,每 5 秒收集一次数据,用这 16 个传感器的数据来验证文中算法。取一周共计 192 小时的数据来训练模型,然后用一天 24 小时的数据作为测试集,预测视野为 600 s 。图 9 和图 10 分别是一个测量服务器入口温度的传感器(Sensors A)和一个测量服务器入口温度的传感器(Sensors B)在测试集上的预测结果。




图 9 Sensors A 预测结果




图 10 Sensors B 预测结果

其中 Sensors A 在测试集上的 RMSE 值为 0.313 °C, 平均误差为 0.253 °C。Sensors B 的 RMSE 值为 0.326 °C, 平均误差为 0.256 °C。

6 结束语

文中主要介绍了基于长短期记忆网络(LSTM)的数据中心温度预测算法, 结合了根据热量局部性原理提出的联合建模框架。该预测算法有很好的适用性和扩展性。在实际搭建的平台上进行了实验, 由实验结果可得, 该算法能够较为准确地预测服务器入口温度, 并且用一个高性能计算机中心的服务器机房收集的实验数据对算法进行了验证。在接下来的工作中, 需要补充一些数据中心特殊情况(如制冷系统失效)的实验数据, 以使该预测模型对突发事件有预警功能。此外, 在温度预测的机制上, 将继续研究通过负载调度调控服务器入口温度和控制冷却系统来调控数据中心温度, 实现绿色数据中心整体温度控制机制, 达到节能的效果。

参考文献:

- [1] ZHOU Rongliang, WANG Zhikui, BASH C E, et al. Data center cooling management and analysis – a model based approach [C]//28th annual IEEE semiconductor thermal measurement and management symposium. San Jose, CA, USA; IEEE, 2012: 98–103.
- [2] CHEN Jinzhu, TAN Rui, XING Guoliang, et al. PTEC: a system for predictive thermal and energy control in data centers [C]//IEEE real-time systems symposium. Rome, Italy; IEEE, 2014: 218–227.
- [3] VARSAMOPOULOS G, BANERJEE A, GUPTA S K S. Energy efficiency of thermal-aware job scheduling algorithms under various cooling models [C]//International conference on contemporary computing. Noida, India; Springer, 2009: 568–580.
- [4] WANG Lizhe, VON LASZEWSKI G, HUANG Fang, et al. Task scheduling with ANN-based temperature prediction in a data center: a simulation-based study [J]. Engineering with Computers, 2011, 27(4): 381–391.
- [5] PAKBAZNIA E, PEDRAM M. Minimizing data center cooling and server power costs [C]//2009 ACM/IEEE international symposium on low power electronics and design. San Francisco, CA, USA; ACM, 2009: 145–150.
- [6] 叶可江, 吴朝晖, 姜晓红, 等. 虚拟化云计算平台的能耗管理[J]. 计算机学报, 2012, 35(6): 1262–1285.
- [7] RANGANATHAN P, JOUPPI N. Enterprise IT trends and implications for architecture research [C]//11th international symposium on high-performance computer architecture. San Francisco, CA, USA; IEEE, 2005: 253–256.
- [8] 李翔, 姜晓红, 吴朝晖, 等. 绿色数据中心的热量管理方法研究[J]. 计算机学报, 2015, 38(10): 1976–1996.
- [9] TANG QINGHUI, MUKHERJEE T, GUPTA S K S, et al. Sensor-based fast thermal evaluation model for energy efficient high-performance datacenters [C]//Fourth international conference on intelligent sensing and information processing. Bangalore, India; IEEE, 2006: 203–208.
- [10] HEATH T, CENTENO A P, GEORGE P, et al. Mercury and freon: temperature emulation and management for server systems [C]//12th international conference on architectural support for programming languages and operating systems. New York, NY, USA; ACM, 2006: 106–116.
- [11] LI Lei, LIANG C J M, LIU Jie, et al. ThermoCast: a cyber-physical forecasting model for data centers [C]//17th ACM SIGKDD international conference on knowledge discovery and data mining. San Diego, California, USA; ACM, 2011: 1370–1378.
- [12] 于洋, 孙成伟, 张冰冰, 等. 云模型 RBF 神经网络的数据中心温度预测[J]. 沈阳理工大学学报, 2013, 32(4): 9–14.
- [13] MOORE J, CHASE J S, RANGANATHAN P. Weatherman: automated, online and predictive thermal mapping and management for data centers [C]//IEEE international conference on autonomic computing. Dublin, Ireland; IEEE, 2006: 155–164.
- [14] CHEN Jinzhu, TAN Rui, WANG Yu, et al. A high-fidelity temperature distribution forecasting system for data centers [C]//IEEE 33rd real-time systems symposium. San Juan, Puerto Rico; IEEE, 2012: 215–224.
- [15] MOORE J, CHASE J, FARKAS K, et al. Data center workload monitoring, analysis, and emulation [C]//Eighth workshop on computer architecture evaluation using commercial workloads. [s. l.]: [s. n.], 2005: 1–8.
- [16] ZHANG Sushu, CHATHA K S. Approximation algorithm for the temperature-aware scheduling problem [C]//2007 IEEE/ACM international conference on computer-aided design. San Jose, CA, USA; IEEE, 2007: 281–288.