

提高数据中心供能中太阳能利用效率的云任务调度优化

党伟超, 王 振, 薛颂东

(太原科技大学 经济与管理学院, 山西 太原 030024)

摘要: 云计算需求在催生数据中心部署应用的同时,造成能耗高和碳排放压力,故云计算环境中可再生能源的高效利用问题被提出。针对太阳能的间歇性非稳特点,文章研究了云任务调度方法来提升数据中心供能中能源利用率。首先,构建预测太阳能产能的深度自回归模型 DeepAR;然后,利用延时容忍型任务和计划工作任务在时间维度上灵活调度的特性,设计云任务调度策略和算法;最后,运用 GluonTS 框架使用真实任务数据集和太阳能产能数据集进行仿真实验。结果表明,计算负荷与太阳能出力的匹配性得到改善,数据中心太阳能供能的利用率得到提升。

关键词: DeepAR 模型; 时间序列预测; 太阳能; 云任务; 调度

中图分类号: TK519 **文献标志码:** A **文章编号:** 1671-5292(2024)09-1170-09

0 引言

随着各地区和各行业数字化转型的深入推进,数据中心市场得到了高速发展。不断提升的云计算需求使得数据中心建设数量快速增加,对能源的需求也显著增长^[1]。2020 年我国的数据中心总能耗达到了 2 000 亿 kW·h,占据了全社会总能耗的 2.7%。如果折算为 CO₂ 排放量,则超过了 4 000 万 t。预计到 2025 年,全球数据中心能耗将导致全球碳排放量增长 3.2%^[2]。

将可再生能源引入数据中心以缓解高碳排放问题已被证明是切实可行的^[3]。可再生能源发电成本逐年下降,使其具备了低碳和低成本的双重属性^[4]。然而可再生能源的可用性并不稳定,例如太阳能在阴天的产量较低,在夜间为零。文献[5]在数据中心中使用储能设备来应对可再生能源的间歇性。虽然储能技术可以在一定程度上缓解这一问题,但电能的存储和利用会涉及到功率转换损失,频繁的充放电会加速电池老化^[6],从而导致了云计算成本的提高。

文献[7]提出了一种 Web 应用程序的负载平衡器,增加了数据中心中对可再生能源的使用,该调度方式是响应式的,并没有通过对能源的预测来帮助调度器做出更好的决策。文献[8]提出的调

度方式中,增加了对未来时刻风速的预测来优化云任务在数据中心的调度过程。本文旨在使用一种调度方式,在不违反服务水平协议(Service Layer Agreement, SLA)的前提下,通过对云任务在时间维度上的调度使能源需求与供应更加匹配。并通过使用 DeepAR 模型预测可再生能源的方式辅助调度器做出决策,达到提升可再生能源利用率的目的。

1 问题描述与建模

1.1 问题描述

云计算环境中的计算结点可能由不同类型的能源提供能量(如电网能源、风能和太阳能)。图 1 展示了在某 1 d 内太阳能的产量和执行任务消耗的能量。当白天的太阳能产量充足时,任务并不能充分地消耗这些能源;而夜晚没有太阳能产出时,任务只能消耗电网电能,能耗需求与太阳能出力




图 1 能耗示例图

Fig.1 Energy consumption example diagram

收稿日期: 2023-08-04。

基金项目: 太原科技大学博士科研启动基金(20202063);太原科技大学研究生教育创新项目(SY2022063);太原科技大学研究生联合培养示范基地项目(JD2022010)。

作者简介: 党伟超(1974-),男,博士,副教授,研究方向为智能计算、软件可靠性、大数据驱动的管理与决策。E-mail: 1996007@tyust.edu.cn

匹配度较低。因此希望将尽可能多的任务转移到可再生能源能够发挥作用的时间段,减少对电网电能的使用。

1.2 任务模型

不同类型的云任务被灵活调度的能力也是不同的^[9]。延时敏感型任务在到达计算环境时就需要被立即处理,如智能医疗、自动驾驶、金融交易业务等;而延时容忍型任务仅需要在完成期限之内结束处理即可,如机器学习训练、科学计算和某些功能即服务(Function-as-a-Service, FaaS)的执行等,具有较大的灵活调度能力。图 2 为不同类型的任务在执行过程中的区别。




图 2 延时敏感型任务和延时容忍型任务模型

Fig.2 Delay sensitive task and delay tolerant task models

延时敏感型任务到达计算环境之后,根据到达时刻 T_{arr} 和计算节点的运算性能可以得到任务的执行时间 ΔT_{proc} 和完成期限 $T_{dll}=T_{arr}+\Delta T_{proc}$ 。从 SLA 中可以获取延时容忍型任务的完成期限 T_{dll} ,根据完成期限和执行时间计算出任务执行的开始时间 T_{start} ,再根据任务的到达时间最终推算出任务可以被延时的最大时间段 $\Delta T_{delay}=T_{dll}-T_{arr}-\Delta T_{proc}$ 。任务在这个时间范围内调度并不会违反 SLA,从而可以利用更多的可再生能源^[10]。

文献[11]将计划工作任务定义为计划在未来的时间点执行的任务。这类任务包括了定期调度的批处理作业,如夜间构建、定期备份、数据库中搜索索引的更新和自动生成的报告等。相关研究表明,大量的工作以固定的时间间隔重复执行,例如周期任务有固定的执行时间,执行时间的间隔即为周期^[12]。超过 40%的任务需要每天执行,重复执行的时间间隔还包括了 12 h, 1 h 和 15 min。延时容忍型任务的执行只能从到达时间开始向未来推迟,而计划工作任务则可以在时间维度上向前后两个方向上移动,具有更强的灵活调度能力,如图 3 所示。




图 3 计划工作任务和延时容忍型任务的对比

Fig.3 Comparison chart of scheduled tasks and delay tolerance tasks

1.3 能耗模型

IT 基础设施的能量消耗可能会受到 CPU 或 GPU 的利用率、内存、磁盘存储和温度等诸多因素的影响。虽然在没有精确工作负载和基础设施特征的情况下很难建立完美的功耗模型,但有研究证明服务器功耗与 CPU 负载呈线性相关^[13],因此可以利用 CPU 利用率来对设备能耗进行建模。这样的建模方法也被用在了现代超大型数据中心的研究中。能耗模型为

$$E(u)=k \cdot E_{max}+(1-k) \cdot E_{max} \cdot u \quad (1)$$

式中: E_{max} 为服务器在满载状态下的最大能耗; k 为服务器在空闲状态下的能耗和满载能耗的比值; u 为服务器实时的 CPU 利用率。

由于负载状态是动态变化的, CPU 利用率也会随时间发生改变,因此将其表示为随时间变化的函数 $u(t)$, 一段时间内服务器的能耗表示为

$$E=\int_{t_0}^t E[u(t)]dt \quad (2)$$

2 可再生能源预测

2.1 产能预测的意义

在响应式的云计算环境中,如果任务没有在可再生能源供能的时间段到达,那么调度器就会判定此时没有可再生能源可用,从而将该任务调度到电网供能的计算结点中进行运算。为了提升可再生能源利用率,本文根据历史数据预测未来可再生能源的产能,这样就可以提前判断可再生能源供能的计算节点是否有能力执行该任务。只要任务完成时间不超过期限,这些任务的执行就会利用到可再生能源供能而不是电网供能,这样就提升了可再生能源的利用率,如图 4 所示。

2.2 时间序列预测问题

时间序列数据(time series data)是在不同时间




图4 产能预测下的任务调度

Fig.4 Task scheduling under capacity prediction

间上收集到的数据,用于所描述现象随时间变化的情况。时间序列分析问题在生活中广泛存在,例如机器设备的能量消耗预测、风速预测、交通流量预测和商品的销售量预测等。时序预测模型有不同的实现原理,可以分为传统的统计学模型和机器学习模型。根据预测步长进行区分,又可以分为单步预测模型和多步预测模型。按照输出的结果,可以将时序预测模型划分为点预测模型和概率预测模型。在某些特定的问题背景下,概率预测更加贴近实际情况,比单点预测更有意义。例如在销售行业中,如果能够得到某种商品未来需求量的概率分布,那么就可以在采购时针对不同业务目标做出辅助决策。概率预测能够描述可再生能源产能变化的概率分布、变化范围,可以获得更全面的预测信息^[14]。

设太阳能产能时间序列 i 在 t 的值为 $z_{i,t}$, 已知的时序列为 $[z_{i,1}, \dots, z_{i,t_0-2}, z_{i,t_0-1}] = z_{i,1:t_0-1}$ 。 t_0 为预测区间开始的时间点, T 为预测区间终止时间点, 需要预测的时间序列为 $[z_{i,t_0}, z_{i,t_0+1}, \dots, z_{i,T}] = z_{i,t_0:T}$ 。 协变量 $x_{i,1:T}$ 在所有的时间点都是已知的, 因此可以建立条件概率分布为

$$P(z_{i,t_0:T} | z_{i,1:t_0-1}, x_{i,1:T}) \quad (3)$$

2.2.1 循环神经网络

对于经典神经网络,以多层感知机为例:网络的输入为 $X \in R^{n \times d}$, 其中: n 为样本数; d 为样本特征的个数; R 为实数。设激活函数为 ϕ , 那么隐藏层的输出为

$$H = \phi(XW_{sh} + b_h) \quad (4)$$

这一层的权重参数为 $W_{sh} \in R^{d \times h}$, 偏差参数为 $b_h \in R^h$, h 为神经元的个数。将隐藏层的输出作为输出层的输入,且输出个数设为 q , 则可以得到输出层的输出为

$$O = HW_{hq} + b_q \quad (5)$$

式中: $W_{hq} \in R^{h \times q}$ 为输出层的权重参数; 偏差参数为 $b_q \in R^q$; 输出变量为 $O \in R^{1 \times q}$ 。

对于时间序列预测问题,数据之间具有时间相关性,例如音乐、语言、文本和视频数据等大部分是连续的,如果将数据序列打乱,那么就可能会失去原先的意义。因此使用含有隐藏状态的循环神经网络可以存储过去的信息,从而更好地处理时序数据。这类模型保留了上一个时间步的隐藏变量 H_{t-1} , 并加入了新的权重系数 $W_{hh} \in R^{h \times h}$ 来表示该隐藏变量的重要程度。因此可以得到时间步 t 的隐藏变量计算方法为

$$H_t = \phi(X_t W_{sh} + H_{t-1} W_{hh} + b_h) \quad (6)$$

式中: $X_t \in R^{n \times d}$ 为当前时间步的输入, $W_{sh} \in R^{d \times h}$ 为隐藏层的权重。

式(6)中记录了隐藏变量 H_t 和 H_{t-1} 之间的关系,从而保留了序列中的历史信息,这里的隐藏变量也被称为隐藏状态。隐藏状态在当前时间步的定义与在前一个时间步是相同的,这样的循环计算就形成了循环神经网络。在时间步 t , 输出层的输出为

$$O_t = H_t W_{hq} + b_q \quad (7)$$

在当前时间步 t 中,输入项有 X_t 和前一个时间步的隐藏状态 H_{t-1} , 进入激活函数为 ϕ 的全连接层,进而得到当前时间步的隐藏状态 H_t 。该隐藏状态将进入下一个时间步,参与隐藏状态 H_{t+1} 的运算,并输入到当前时间步的全连接输出层。

2.2.2 DeepAR 模型

DeepAR^[15]是 Amazon 团队提出的基于深度学习的时间序列预测方法。它是一个自回归循环神经网络时间序列模型,内部包含了循环神经网络(LSTM 或 GRU 单元)且具有隐藏状态。该方法可以将多个相关的时间序列组合在一起,不仅可以从相似的时间序列中学习全局模型,还可以灵活地实现点预测和概率预测。在预测过程中也可以将额外的特征(协变量)纳入考虑,并完成多步预测。

太阳能产量在每天上午呈上升趋势,中午时达到峰值,下午的产量逐渐降低,呈现出了周期性的变化。而 DeepAR 模型自回归的特性能够有效保留数据周期性的变化,对周期性较强的太阳能数据集较为适用。对于数据集中的缺失值,DeepAR 模型可以在模型内部进行填充,在减少数据预处理工作的同时也使得对缺失值的处理更加准确。该模型可以生成可选时间跨度的多步预测结果,可以一次性预测云任务调度窗口中的多

个数值,降低了调度器在重复计算过程中对资源的消耗。

模型训练阶段从输入数据的输入层开始,对于每个时间步 t ,网络的输入包括上一个时间步的取值 $z_{i,t-1}$ 、上一个时间步的状态 $h_{i,t-1}$ 和协变量 $x_{i,t}$,计算出当前状态 $h_{i,t}=h(h_{i,t-1},z_{i,t-1},x_{i,t},\Theta)$,再计算似然函数 $l(z|\theta)$ 的参数 $\theta_{i,t}=\theta(h_{i,t},\Theta)$,并通过最大化对数似然来学习网络的参数。

$$L=\sum_i \sum_t \log l(z_{i,t}|\theta(h_{i,t})) \quad (8)$$

时间步 t_0 为预测阶段的开始时刻,将训练好的数据放入网络中,就可以得到初始的状态 h_{i,t_0-1} ,进而使用祖先采样输出预测结果。在每个时间步进行随机采样得到 $\tilde{z}_{i,t} \sim l(\cdot|\theta_{i,t})$,并将这个采样值输入到下一个时间步中,重复这个过程就可以得到预测区间的所有采样值,进而计算所需要的目标值。

预测过程中使用的似然函数需要根据数据特征来做具体选择,如高斯分布似然函数、负二项分布似然函数等。对可再生能源产量进行预测可以使用高斯似然模型,使用期望和标准差对其进行参数化处理,即 $\theta=(\mu,\sigma)$ 。使用 softplus 作为激活函数,其目的在于使方差大于 0。计算式为

$$l_G(z|\mu,\sigma)=\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z-\mu)^2}{2\sigma^2}\right) \quad (9)$$

$$\mu(h_{i,t})=w_\mu^T h_{i,t}+b_\mu \quad (10)$$

$$\sigma(h_{i,t})=\log\left[1+\exp(w_\sigma^T h_{i,t}+b_\sigma)\right] \quad (11)$$

式中: w_μ^T 和 w_σ^T 为权重参数; b_μ 和 b_σ 为偏差参数; $\mu(h_{i,t})$ 和 $\sigma(h_{i,t})$ 分别为函数的均值和标准差。

3 任务调度流程

3.1 前向调度

对可再生能源产能做出预测关注的是任务到达计算环境后未来发生的事情。在产能能够满足延时容忍型任务的能耗需求时,任务会被加载到执行队列中进行等待,以此来完成在时间维度上对任务的后向调度。然而在某些时候,对任务进行后向调度并不能完成对可再生能源的利用。图 5 中以太阳能为例,在日落之后已经没有太阳能能被用来执行任务。如果这时到达的任务受到了完成期限的限制,无法等待未来能够发挥效用的可再生能源,那么这部分任务就只能消耗电网电能。




图 5 前向调度示意图

Fig.5 Forward scheduling diagram

大部分情况下太阳能出力和任务能耗需求是很难匹配的,特别是在太阳能产能峰值时间段,能源产量会比任务的需求量高出很多。任务只被进行后向调度,无法利用先前产生的可再生能源,白天剩余的太阳能也只能被浪费掉。

可以双向调度的计划工作任务包括了周期性任务、批处理作业和数据处理等。周期性任务以固定的时间间隔执行,这类任务在计算环境中的执行时间是可知的。在计算资源允许的条件下,调度器可以选择将任务执行的开始时间提前。在可再生能源可用时,尽早为计算节点分配任务。批处理作业的执行通常不具有严格的时间要求,可以将其安排在较早的时间执行,以利用可再生能源供能下的计算资源,减少在高峰期对资源的需求。将计算环境中执行时间已知的任务提前分配到计算节点的过程,可视为对计划工作任务的前向调度。前向调度窗口是指调度器提前执行计划工作任务的最大时间范围,窗口大小按照小时数进行划分。本文利用计划工作任务可以被前向调度的性质,在原有的调度流程中为其增加前向调度窗口。原本执行时间在日落之后的任务就可以被向前调度到太阳能能够发挥效用的时间段,从而更加充分地消耗掉当天产生的可再生能源。

3.2 整体调度流程

任务到达云计算环境中需要获取到的参数有:任务的到达时间、任务大小和截止日期。根据任务的不同分类,将计划工作任务按照前向调度窗口的大小进行前向调度。再将所有的任务根据其大小进行建模,获取到任务被执行所需要的能耗值。与此同时调度系统会根据当前可再生能源数据,对未来的能源产能进行预测。调度器会判断可再生能源供能的计算节点在当前或未来是否有足够的能量,使任务在不违反完成期限的条件下被执行。当资源能够满足任务运算时,任务执行的开始时间就是到达时间;否则任务会等到可再生

能源可用时被执行。

当系统得到新的任务请求时, 会判断新任务的加入是否使得现有队列中的任务违反完成期限, 以此来决定是否将新任务加入到任务队列中。处理流程如图 6 所示。

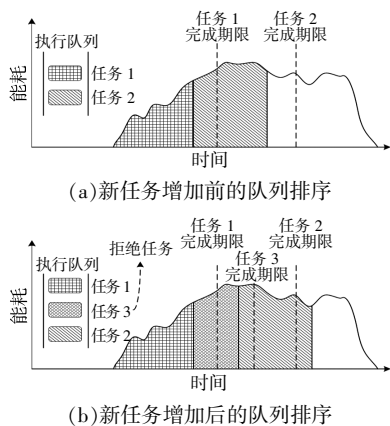


图 6 新任务到达时的 SLA 判断

Fig.6 SLA judgment when new tasks arrive

原来队列中有两个任务, 分别是任务 1 和任务 2, 它们的执行时间范围和完成期限见图 6(a); 当任务 3 请求加入执行队列时, 如图 6(b) 所示, 因为它的完成期限早于任务 2, 需要将其排到任务 2 之前来执行。但是这会使得任务 2 的执行违反完成期限, 系统就会拒绝任务 3 加入到执行队列中。调度系统的目的是尽可能多地使用可再生能源, 当任务由于受到完成期限的限制无法使用可再生能源时, 系统将会使用电网电能保证该任务 (任务 3) 的执行。如果新的任务请求没有导致发生任何冲突, 那么新的任务就会被允许加入。

综上所述, 当可再生能源产量能够满足计算需求, 并且任务的执行不会违反完成期限, 这些任务就会被调度到可再生能源供能的计算节点完成运行。期间, 被拒绝掉的任务会被调度到电网供能的计算节点完成运行。完整的任务调度流程见图 7。

4 实验

4.1 实验数据集和环境

实验的硬件环境为 Intel (R) Core (TM) i5-7200U CPU @ 2.50 GHz, 8 GRAM, NVIDIA GeForce 940MX。软件环境为 Windows10, PyCharm (Professional Edition) 2021 编译环境。使用了 MXNet1.7.0 开源深度学习框架和 GluonTS0.12.3 时间序列建模库完成可再生能源产量预测实验。

实验中使用的任务数据集为阿里巴巴集群跟

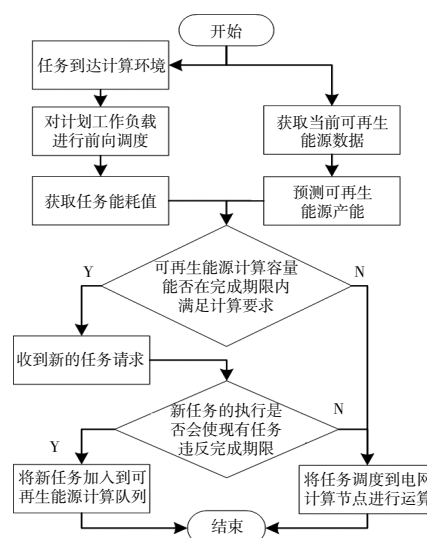




图 7 任务调度流程图

Fig.7 Task scheduling flowchart

踪负载数据集^[6], 使用了机器学习场景和边缘计算场景中 1 d 内的 1 374 个任务数据, 其中包含 648 个延时容忍型任务和 726 个计划工作任务。所有任务的完成期限为各任务执行日期的当天 24:00。可再生能源数据集来自两个不同的太阳能发电站在 2022 年 1 月 18 日-2022 年 2 月 1 日的太阳能产量, 采样间隔为 10 min。图 8 为太阳能产量 1 d 中的分布情况。



(a) 太阳能发电站 1



(b) 太阳能发电站 2

图 8 太阳能产量分布

Fig.8 Distribution of solar energy production

由图 8 可见,发电站 1 每 10 min 的能源产量均值为 157.73 kW·h,标准差为 83.76 kW·h。发电站 2 的能源产量更高,离散程度更大,其产能均值为 167.70 kW·h,标准差为 87.43 kW·h。在能源预测部分将数据集中前 14 d 的数据作为训练集用于模型训练,最后 1 d 的数据作为测试集。

4.2 预测模型评价指标

选用以下评价指标对使用 DeepAR 模型的可再生能源产能预测结果进行评价。设产能预测值为 $\hat{Y}_t = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n\}$, 真实值为 $Y_t = \{y_1, y_2, \dots, y_n\}$, l 为预测长度。

平均绝对比例误差 (Mean Absolute Scale Error, MASE):

$$MASE = \frac{1}{l} \frac{\sum_{t=1}^l |Y_t - \hat{Y}_t|}{\frac{1}{T-m} \sum_{t=m+1}^T |Y_t - Y_{t-m}|} \quad (12)$$

MASE 是将平均误差除以缩放系数来计算得出的,缩放系数取决于时间序列的采样频率 m 。因此该指标非常适合评估具有周期性或季节性特征的数据集,其值越低表示模型越准确。

对称平均绝对百分比误差 (symmetric Mean Absolute Percentage Error, sMAPE):

$$sMAPE = \frac{1}{l} \sum_{t=1}^l \frac{2|Y_t - \hat{Y}_t|}{(|Y_t| + |\hat{Y}_t|)} \quad (13)$$

sMAPE 反映的是预测值和真实值之间的误差大小,其值越小表示误差越小,模型的拟合度越高。

4.3 预测结果分析

本文对两个不同的太阳能发电站的能源产量进行实验预测,每个训练集包含了 14 d 范围内采样间隔为 10 min 的 2016 个数据点,预测的数据为未来 1 d 的 144 个数据点。在预测模型中,循环神经网络的层数设为 2 层,每层有 40 个神经元,在层之间加入比率为 0.1 的 Dropout 层,数据批次大小为 50,学习率为 0.001,模型使用的似然函数为正态分布函数,内部使用 LSTM 循环神经网络单元。将模型进行多次迭代训练,得到的预测曲线如图 9 所示。

分位数可以为预测区间提供上限和下限,取值为 $[0, 1]$ 。图 9 中采用 0.9 和 0.1 的分位数,构造出置信度为 80% 的置信区间,0.5 分位数下的预




图 9 太阳能产量预测效果

Fig.9 Effect chart of solar energy production forecast


测值为预测中值。预测区间覆盖了大部分的观测值,预测值与真实值较为接近。深度自回归循环神经网络能够较好地提取时间序列数据的内部特征,其中的循环神经网络保留了网络结构,减少了采样时的计算量。该算法模型可以捕获时序数据中的周期性信息,使预测模型能够准确地预测出未来太阳能产量的变化趋势。太阳能发电站 1 能源产量的预测结果中,MASE 为 0.55,sMAPE 为 1.28。太阳能发电站 2 数据集的预测结果中,MASE 为 0.32,sMAPE 为 1.21。从评价指标中可以看出,模型输出的预测值和真实值相比误差较小,DeepAR 模型对太阳能产量数据的预测具有良好的准确度和泛化能力。

4.4 调度策略实验


使用离散事件仿真框架 Simpy 实现了任务调度流程。其中包括了 3 种调度策略:响应式调度策略只有在当前的能源充足时,才会使任务加入可再生能源供能的计算节点;预测调度策略加入了对未来的可再生能源产量的预测,为可再生能源计算节点保留了更多的任务;最后一种策略则是在预测的基础上加入了前向调度窗口,按照前向调度窗口的大小为任务设置相应的提前执行时

间,并按小时数对窗口进行划分,较小的调度窗口会限制任务被灵活调度的能力,而较大的窗口则会造成调度过程中的资源浪费。在本文涉及的任务和太阳能数据集下经过优化实验,调度窗口大小的优化结果为 8 h。


使用不同的分位数可以对能源产量进行不同乐观和保守程度下的差异化预测。分位数取 0.5 时,预测模型输出的是能源中值预测序列;当分位数取值小于 0.5 时,输出的预测值低于中值,实现对能源的保守预测;分位数取值大于 0.5 时,则会得到高于中值的预测值,即为对能源的乐观预测。实验中取 0.1, 0.5 和 0.9 的分位数值分别对应对能源产量的保守预测、中值预测和乐观预测。在机器学习场景和边缘计算场景下,对预测调度策略和加入前向调度窗口的调度策略的有效性进行验证。图 10 为各组实验中可再生能源的利用率情况。




(a) 太阳能发电站 1



(b) 太阳能发电站 2



(c) 太阳能发电站 1



(d) 太阳能发电站 2

图 10 不同策略下的可再生能源利用率

Fig.10 Renewable energy utilization rates under different strategies

在任务调度系统中加入了对可再生能源产量的预测后,能源利用率相较于响应式调度策略总体上得到了提升。机器学习任务比边缘计算任务具有更宽松的完成期限,任务有更多的时间等待太阳能发挥效用,具有更大的灵活调度潜能。边缘计算任务对执行效率的要求更高,任务的完成期限更加严格。因此在不同太阳能发电站供电的情况下,使用预测调度策略后机器学习任务的能源利用率提升量都比边缘计算任务更高。机器学习任务在使用两个不同太阳能发电站供电的情况下,可再生能源利用率平均提升了 24.0% 和 26.4%。边缘计算任务在使用来自不同发电站的能源时,能源利用率平均提升了 3.6% 和 5.3%。不同分位数值的使用决定了对能源预测的乐观和保守程度。当有充足的可再生能源为任务供电时,乐观的预测有助于将更多的任务调度到这类能源供电的计算节点,从而更有效地提升可再生能源的利用率。

为任务调度系统加入前向调度窗口后,计划工作任务被双向调度的潜能得以发挥,大量的任务被调度到了可再生能源供电的计算节点。由于实验中机器学习场景下的任务整体能耗需求超过了能源总量,因此任务的执行消耗了全部的可再生能源,使得可再生能源利用率达到了 100%。乐观的预测虽然会使任务充分消耗可再生能源,但耗尽可再生能源后队列中剩余的任务需要被调度到电网供电的计算节点保证执行,这样就会额外花费调度成本,此时应谨慎选择乐观预测。在边缘计算场景下,任务的整体能耗需求较低,可再生能源供电较为充足,前向调度窗口的应用和对于能源较乐观的预测有助于充分消耗可再生能源。

5 结论

本文在响应式调度策略的基础上,使用了深度学习模型 DeepAR 对可再生能源产量进行了预测,并使用评价指标评估了预测结果的准确性。提出的调度策略可以使延时容忍型任务在被调度时,能够预知未来可再生能源的计算容量,为可再生能源供能的计算节点保留更多的任务。系统中还增加了前向调度窗口,实现了对计划工作任务的双向调度。使用了真实的太阳能数据集和任务请求数据集,对提出的基于能源产量预测的保守预测、中值预测、乐观预测调度策略和加入前向调度窗口的调度策略进行了验证。结果表明,基于能源预测的调度策略和增加前向调度窗口的调度策略能够使任务请求和可再生能源出力实现高度匹配,有效提升了可再生能源在数据中心的利用率。

参考文献:

- [1] Liu Y N, Wei X X, Xiao J Y, et al. Energy consumption and emission mitigation prediction based on data center traffic and PUE for global data centers[J]. *Global Energy Interconnection*, 2020, 3(3): 272-282.
- [2] 马钊, 赵志刚, 孙媛媛, 等. 新一代低压直流供用电系统关键技术及发展展望[J]. *电力系统自动化*, 2019, 43(23): 12-22.
- [3] Fan Y, Yi B W. Evolution, driving mechanism, and pathway of China's energy transition [J]. *Management World*, 2021, 37(8): 95-105.
- [4] 陈冬林, 马一帆, 邹安琪. 基于可再生能源消纳的数据中心负荷调度研究综述[J]. *计算机工程与科学*, 2023, 45(5): 790-801.
- [5] 朱灿元, 杨超, 李舒涛, 等. 考虑清洁能源与储能的分布式数据中心低碳调度策略 [J]. *智慧电力*, 2023, 51(2): 16-23.
- [6] Liu L J, Li C, Sun H B, et al. BAAT: Towards dynamically managing battery aging in green datacenters [A]. 2015 45th Annual IEEE/IFIP International Conference on Dependable Systems and Networks[C]. Rio de Janeiro: IEEE, 2015. 307-318.
- [7] Toosi A N, Qu C H, Dias de Assunção M. Renewable-aware geographical load balancing of web applications for sustainable data centers [J]. *Journal of Network & Computer Applications*, 2017, 83: 155-168.
- [8] 李寒. 基于时空信息的可再生能源预测方法研究[D]. 北京: 北京工业大学, 2021.
- [9] Chen M, Gao C W, Shahidepour M, et al. Internet data center load modeling for demand response considering the coupling of multiple regulation methods [J]. *IEEE Transactions on Smart Grid*, 2021, 12(3): 2060-2076.
- [10] 杨挺, 姜含, 侯昱丞, 等. 基于计算负荷时-空双维迁移的互联多数据中心碳中和调控方法研究[J]. *中国电机工程学报*, 2022, 42(1): 164-177.
- [11] Wiesner P, Behnke I, Scheinert D, et al. Let's wait a while: how temporal workload shifting can reduce carbon emissions in the cloud [A]. 22nd International Middleware Conference (Middleware '21)[C]. New York: Association for Computing Machinery, 2021. 260-272.
- [12] 陈磊. 异构多核架构下的高能效混合任务调度算法研究[D]. 重庆: 重庆邮电大学, 2022.
- [13] Dabbagh M, Hamdaoui B, Guizani M, et al. An energy-efficient VM prediction and migration framework for overcommitted clouds [J]. *IEEE Transactions on Cloud Computing*, 2018(6): 955-966.
- [14] 黎静华, 骆怡辰, 杨舒惠, 等. 可再生能源电力不确定性预测方法综述[J]. *高电压技术*, 2021, 47(4): 1144-1157.
- [15] Salinas D, Flunkert V, Gasthaus J. DeepAR: Probabilistic forecasting with autoregressive recurrent networks [J]. *International Journal of Forecasting*, 2020, 36(3): 1181-1191.
- [16] Alibaba Cluster-trace-gpu-v2020 Trace Data[EB/OL]. <https://github.com/alibaba/clusterdata>, 2023-12-28.

Cloud tasks scheduling optimization for improving solar energy utilization efficiency in data center power supply

Dang Weichao, Wang Zhen, Xue Songdong

(School of Economics and Management, Taiyuan University of Science and Technology, Taiyuan 030024, China)

Abstract: Cloud computing demand has caused high energy consumption and carbon emission pressure while generating data center deployment applications, so the efficient utilization of renewable energy in cloud computing environment is proposed. Aiming at the intermittent non-stationary characteristics of solar energy, which is a specific form of renewable energy, we study the cloud task scheduling method to enhance the energy utilization in data center energy supply. DeepAR, a deep autoregressive model for predicting solar energy production capacity, is constructed to design cloud task scheduling strategies and algorithms by taking advantage of the flexible scheduling characteristics of delay-tolerant tasks and scheduled workloads in the time dimension, and simulation experiments are carried out using real task datasets and solar energy production capacity datasets by applying the GluonTS framework. The results show that the matching between computing load and solar power output is improved, and the utilization of solar power supply in data centers is enhanced.

Keywords: DeepAR model; time series prediction; solar energy; cloud tasks; scheduling