

DOI:10.19651/j.cnki.emt.2108118

# 基于改进 DDPG 的中央空调负荷预测方法研究 \*

贾 静 高文忠

(上海海事大学商船学院 上海 201306)

**摘要:**为降低因节假日引起的建筑内部得热对大型中央空调系统负荷预测精度的负面影响,以上海世博园区某办公建筑群作为研究区域,引入新的日期特征 DPH,在现有深度确定性策略梯度网络结构的基础上,利用长短期记忆神经网络替换深度确定性策略梯度的全连接神经网络,提出基于循环确定性策略梯度的大型中央空调系统冷负荷预测方法。研究结果表明,考虑 DPH 日期特征的改进算法预测模型能够捕捉因节假日引起的负荷变化趋势,有效提高预测准确性,预测精度达 0.951,误差值为 7.08%。

**关键词:**空调负荷预测;冷热电三联供系统;长短期记忆神经网络;循环确定性策略梯度;深度强化学习

中图分类号: TP181 文献标识码: A 国家标准学科分类代码: 480.8

## Research on load forecasting of central air-conditioning system based on improved deep deterministic policy gradient

Jia Jing Gao Wenzhong

(Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China)

**Abstract:** To reduce the negative impact of inner heat gain of buildings caused by holidays on the accuracy of load forecasting in large central air-conditioning systems, an office building complex in Shanghai Expo Park is taken as the research area, a cooling load forecasting method for large central air-conditioning system based on improved deep deterministic policy gradient is proposed. New date-related feature named days from previous holiday is introduced, the fully connected neural network in deep deterministic policy gradient structure is replaced by long short-term memory neural network, and a load forecasting model based on recurrent deterministic policy gradient is constructed. The experimental results show that the improved prediction model within days from previous holiday can timely capture the load change trend caused by holidays, effectively improve the prediction accuracy which is 0.951 and the error value is 7.08%.

**Keywords:** air-conditioning load forecasting; CCHP; long short-term memory; recurrent deterministic policy gradient; deep reinforcement learning

## 0 引言

全球经济快速发展,能源消耗直线上升,二氧化碳排放量逐年增加。中国在 2021 年的《政府工作报告》中明确提出要“扎实做好碳达峰、碳中和各项工作”,“二氧化碳排放力争于 2030 年前达到峰值,努力争取 2060 年前实现碳中和”。作为全球最大的发展中国家,早在 2018 年,中国的能耗及二氧化碳排放量已占全球总量的 30%<sup>[1]</sup>。以住宅、商厦等为代表的高层建筑能耗在总能耗中占比超 40%<sup>[2]</sup>,空调系统作为主要耗能设备,其运行产生的二氧化碳等温室气体已经导致全球变暖,加快实现碳中和迫在眉睫<sup>[3]</sup>。为

降低碳排放,同时提高能源利用率,对空调负荷建立人工智能预测模型,在此基础上优化空调系统的运行策略具有明显的节能潜力。

人工智能预测模型是基于空调系统的运行数据,自主学习负荷与影响因素之间的复杂关系。影响模型预测精度的因素主要有两方面:1)特征工程,刘新宇等<sup>[4]</sup>考虑了影响因素之间的耦合性,先用主成分分析法选出重要特征,再提出了改进灰色神经网络算法模型预测商场冷负荷,结果表明进行主成分分析后的改进算法模型效果最好;Shao 等<sup>[5]</sup>综合考虑天气变量和系统运行参数,提出了支持向量机(support vector machines, SVM)预测模型分析宾馆能

收稿日期:2021-10-19

\* 基金项目:上海科学技术委员会项目(18040501800)、上海市科技计划项目(20DZ2252300)资助

耗;2)预测算法,Wang 等<sup>[6]</sup>选用了 12 种常用预测模型来研究各种不确定性影响因素与建筑热负荷之间的关系,对比发现极端梯度提升(extreme gradient boosting, XGBoost)算法和长短期记忆(long short-term memory, LSTM)算法的预测结果更为精确。随着人工智能技术的发展与算法的改进,深度强化学习作为新兴技术已经在路径规划<sup>[7]</sup>、图像识别<sup>[8]</sup>、故障诊断<sup>[9]</sup>等方面取得了很好的效果。很多学者也开始尝试将深度强化学习算法应用于负荷预测领域,期望解决复杂不确定性因素对负荷波动影响的问题。Liu 等<sup>[10]</sup>提出了 3 种深度强化学习算法,分别对建筑能耗进行了单步和多步预测,结果表明所提算法比监督学习算法的精确度更高。

现有研究结果表明了特征工程和预测算法对于提高大型中央空调系统负荷预测精度的重要性,但仍有一些问题亟待解决。一方面,大型中央空调系统的负荷受多种不确定性因素影响而上下波动,常见影响因素有天气条件、设备状态、建筑结构、人员入住率等。这些影响因素具有随机性且都是不可避免的,特别是建筑结构、人员入住率这类抽象影响因素很难用统计数据来衡量,如何通过间接特征来反映这类抽象影响因素的变化显得尤为重要。另一方面,大型中央空调系统的应用场景通常包括商业建筑、高层住宅及办公楼宇,所研究的负荷预测本质上是时间序列分析,如何根据负荷数据的时间特性来改进深度强化学习算法是另一难题。

针对以上两点不足,以上海世博园区某办公建筑群的夏季空调冷负荷为研究对象,分析历史冷负荷数据,根据工作日和节假日的负荷差异,引入新的日期特征:距离上个节假日的天数(days from previous holiday, DPH)来反映因节假日引起的建筑内部得热和人员入住率的变化;鉴于 LSTM 处理时序预测问题的优越性,利用 LSTM 神经网络改进深度确定性策略梯度(deep deterministic policy gradient, DDPG),改进后的循环确定性策略梯度(recurrent deterministic policy gradient, RDPG)算法用于预测受复杂因素影响的大型中央空调系统的夏季冷负荷;此外,分别搭建基于 DDPG 算法和 LSTM 算法的空调冷负荷预测模型,通过对比分析,验证改进 DDPG 算法在大型中央空调系统冷负荷预测方面的有效性。

## 1 基本原理

### 1.1 马尔可夫决策过程(Markov decision process, MDP)

强化学习<sup>[11]</sup>算法是通过学习智能体与环境的交互来解决序列决策问题,交互过程用四元组表示,即  $MDP: \{S, A, p, r\}$ ,其中  $S$  为状态空间,  $A$  为动作空间,  $p = (s_{t+1} | s_t, a_t)$  为状态转移概率函数,  $r(s_t, a_t, s_{t+1})$  为奖励函数。初始状态下,智能体从状态空间  $S$  中感知到环境  $s_0$ ,基于策略函数  $\pi(a_t | s_t)$  将环境  $s_t$  映射到动作  $a_t$ ,做出动作  $a_0$ ,环境相应地改变到下一个状态  $s_1$ ,并反馈给智能体一个即时奖励

$r_1$ ,然后智能体根据状态  $s_1$  做出下一个动作  $a_1$ ,交互过程依此重复直到环境状态终止。 $MDP$  的一个轨迹描述为  $\tau = s_0, a_0, s_1, r_1, a_1, \dots, s_{t-1}, a_{t-1}, s_t, r_t$ 。对于给定的策略函数  $\pi(a_t | s_t)$ ,折扣回报  $R(\tau)$  用式(1)表示。

$$R(\tau) = \sum_{t=0}^{T-1} \gamma^t r_{t+1} \quad (1)$$

其中,  $\gamma \in [0, 1]$  是折扣率。

强化学习的目标是寻找最优策略来最大化期望回报  $J(\tau)$ ,用式(2)表示。

$$J(\tau) = E_{\tau \sim \pi}[R(\tau)] = E_{\tau \sim \pi} \left[ \sum_{t=0}^{T-1} \gamma^t r_{t+1} \right] \quad (2)$$

### 1.2 演员-评论员(actor-critic, AC)框架

AC 框架<sup>[12]</sup>结合强化学习中的值函数与策略函数,其中演员是指策略函数  $\pi(a_t | s_t)$ ,用于学习参数化策略来获得尽可能高的回报;评论员是指值函数  $V^\pi(s_t)$ ,用式(3)表示,用于评估值函数的好坏并更新策略。AC 框架的优势在于可以进行单步更新参数,而不需要等到回合结束,大大提升了交互效率。

$$V^\pi(s_t) = E_{\tau \sim \pi} \left[ \sum_{t=0}^{T-1} \gamma^t r_{t+1} \mathbb{1}_{s_{t+1}=s} \right] \quad (3)$$

其中,  $\tau_{s_0}$  表示轨迹  $\tau$  的起始状态。

### 1.3 DDPG 算法

深度 Q 网络(deep Q-network, DQN)算法<sup>[13]</sup>通过引入深度神经网络作为函数逼近器来评估状态-动作值函数  $Q^\pi(s_t, a_t)$ ,也叫 Q 函数,用式(4)表示。DQN 最大的优势在于经验回放池和目标网络的引入,可以稳定学习目标,有效解决维度灾难。目前,DQN 在离散空间已经有很好的应用,但其存在过估计问题。

$$Q^\pi(s_t, a_t) = E_{s_{t+1} \sim p(s_{t+1} | s_t, a_t)} [r(s_t, a_t, s_{t+1}) + \gamma V^\pi(s_{t+1})] \quad (4)$$

通过整合 DQN 算法和 AC 框架,在确定性策略梯度(deterministic policy gradient, DPG)算法的基础上提出了 DDPG 算法<sup>[14]</sup>来解决连续动作问题。DDPG 结合了 AC 框架和 DQN 算法的优点,包含 4 种神经网络,分别是演员网络、目标演员网络、评论员网络和目标评论员网络。其中带权重  $\theta^\pi$  的演员网络和带权重  $\theta^{\pi'}$  的目标演员网络分别用来描述策略函数  $\mu(s | \theta^\pi)$  和  $\mu'(s | \theta^{\pi'})$ ;带权重  $\theta^Q$  的评论员网络和带权重  $\theta^{Q'}$  的目标评论员网络分别用来描述状态-动作值函数  $Q(s, a | \theta^Q)$  和  $Q'(s, a | \theta^{Q'})$ ,DDPG 也存在过估计问题。

### 1.4 评价指标

采用 4 种评价指标评估预测模型的性能,分别是平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、判定系数(coefficient of determination,  $R^2$ )和变差系数(coefficient of variance, CV),用式(5)~(8)表示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (7)$$

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

其中,  $y_i$  和  $\hat{y}_i$  分别表示时刻  $i$  处的真实值和预测值;  $n$  表示样本总数;  $\bar{y}_i$  表示真实值的平均值。

## 2 改进 DDPG 算法

传统 DDPG 算法的网络结构由多层感知器 (multi-layer perceptron, MLP) 构成, MLP 非相邻两层之间的网络是不连接的, 无法解决时序数据的相关问题。而应用于办公建筑群的大型中央空调系统, 其夏季供冷分为工作日和节假日, 具有明显的周期性, 对夏季冷负荷的预测本质上是对时间序列进行分析。考虑到在过往的研究中, LSTM 作为改进型循环神经网络 (recurrent neural network, RNN), 在时间序列数据的预测上有着非常明显的优势。因此, 对 DDPG 算法做出改进, 用 LSTM 神经网络代替 DDPG 网络结构中的估计演员网络和目标演员网络, 基于 LSTM 神经网络更新策略函数, 并依据当前策略更新动作, 也就是得到下一时刻的预测负荷值。改进后的 RDPG 算法中, LSTM 神经网络被用作函数逼近器来描述空调负荷预测的交互过程, 相比于 MLP 更适用于时间序列数据的预测问题。RDPG 的算法原理如图 1 所示。

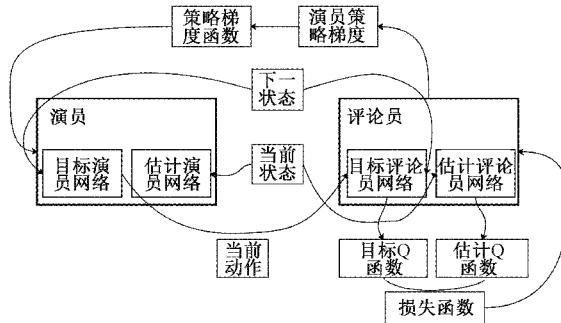


图 1 RDPG 算法原理

首先对演员和评论员中的神经网络进行参数初始化, 并设置经验回放池和最大更新片段  $episode$ ; 初始状态下, 估计演员网络和估计评论员网络感知到环境  $s_0$ , 并基于当前策略做出动作  $a_0$ , 然后目标演员网络和目标评论员网络跳转到下一个状态  $s_1$ , 再根据新的状态作出相应动作  $a_1$ , 同时反馈一个标量奖励  $r_1$  给智能体, 该更新过程描述为集合  $\{s_t, a_t, r_t, s_{t+1}\}$  存放在经验回放池中; 评论员从经验回放池中随机采样总数为  $N$  的批处理样本, 并更新最小损失

函数, 演员基于采样策略梯度进行状态更新, 整个过程不断重复直到  $episode$  达到最大值。RDPG 算法伪代码如算法 1 所示。

### 算法 1 RDPG 算法

```

1: 随机初始化演员和评论员的网络参数 ( $\theta^\mu, \theta^{\mu'}$ ) 和
   ( $\theta^Q, \theta^{Q'}$ )
2: 初始化经验回放池  $\mathbf{R}$ 
3: for  $episode=1$  to  $M$  do
4:   初始化环境  $s_0$ 
5:   for  $t=1$  to  $T$  do
6:     根据当前策略选择动作  $a_t = \mu(s_t | \theta^\mu)$ 
7:     执行动作  $a_t$ , 反馈即时奖励  $r_t$ , 更新状态  $s_{t+1}$ 
8:     将  $\{s_t, a_t, r_t, s_{t+1}\}$  存储到经验回放池  $\mathbf{R}$  中
9:   从经验回放池  $\mathbf{R}$  中随机采样  $N$  个集合构成批处
理样本
10: 令  $y_i = r_i + \gamma Q'(s_{i+1}, \mu'(s_{i+1} | \theta^{\mu'}) | \theta^{Q'})$ 
11: 更新评论员网络参数, 得到最小损失函数:
     $L = \frac{1}{N} \sum_{i=1}^N (y_i - Q(s_i, a_i | \theta^Q))^2$ 
12: 基于采样策略梯度更新演员策略:
     $\nabla_{\theta^\mu} J(\tau) \approx \frac{1}{N} \sum_{i=1}^N \nabla_a Q(s, a | \theta^Q) |_{s=s_i, a=\mu(s_i)} \cdot$ 
     $\nabla_{\theta^\mu} \mu(s | \theta^\mu) |_{s=s_i}$ 
13: 更新目标网络参数:
     $\theta^{Q'} \leftarrow \tau \theta^Q + (1 - \tau) \theta^{Q'}$ 
     $\theta^{\mu'} \leftarrow \tau \theta^\mu + (1 - \tau) \theta^{\mu'}$ 
14: end for
15: end for

```

## 3 基于 RDPG 的大型中央空调系统冷负荷预测模型

### 3.1 数据描述

以上海世博园区某办公建筑群的夏季空调冷负荷为研究对象, 搭建基于 RDPG 算法的短期空调负荷预测模型, 研究天气、建筑结构、人员入住率等不确定性因素对夏季空调负荷的影响, 验证改进算法的准确性。该建筑群由冷热电三联供系统进行供冷, 冷负荷由供回水温差及冷冻水流计算获得, 具体计算方法参考文献[15]。冷热电三联供系统的运行时间为每个工作日的 6~18 时, 运行数据的采集范围从 2019 年的 6 月 16 日~9 月 30 日, 采样间隔为每 5 min 一次, 历史负荷数据总计 10 080 条。此外, 从当地气象站采集了与负荷时间范围相对应的气象参数, 包括室外干球温度 (outdoor dry-bulb temperature, OT)、露点温度 (dew-point temperature, DT)、最大风速 (max wind speed, WS) 和平均相对湿度 (average relative humidity, RH), 采

样间隔为每 1 h 一次。历史冷负荷及气象参数的数据描述如表 1 所示。为了匹配历史冷负荷与气象参数的采样间隔,以小时划分区间,将每一个区间内的所有 5 min 冷负荷数据进行求和平均,得到每小时的平均负荷值,以便进行提前 1 h 的短期负荷预测。

表 1 历史负荷及气象参数的数据描述

变量名称	采样间隔	单位	范围	平均值
历史冷负荷	5 min	MW	[0, 32.06]	16.71
最大风速	1 h	m/s	[0, 13.40]	4.20
平均相对湿度	1 h	%	[27.00, 96.00]	75.72
室外干球温度	1 h	℃	[17.40, 38.10]	26.93
露点温度	1 h	℃	[10.40, 27.60]	21.88

### 3.2 历史冷负荷数据分析

三联供系统为世博园区的办公建筑群供能,受工作日和节假日影响,夏季空调冷负荷实质上是时间序列数据,图 2 为 2019 年 7 月 8 日~8 月 11 日的历史负荷数据曲线图,根据办公类建筑的生产生活特性分为明显的工作日和节假日,如图 2(a) 所示;工作日的空调冷负荷具有日周期性,如图 2(b) 所示;节假日空调系统停用。将冷负荷按距离上个节假日的天数分类,进行时间特性分析,得到图 3 所示结果,横坐标分别表示距上个节假日 1~5 天,纵坐标表示相同日期类型的空调冷负荷总和。从图 3 中可以看出,距离上个节假日越近,即天数的值越小,其冷负荷总和也就越高。这是因为在节假日期间建筑内部得热,节假日后系

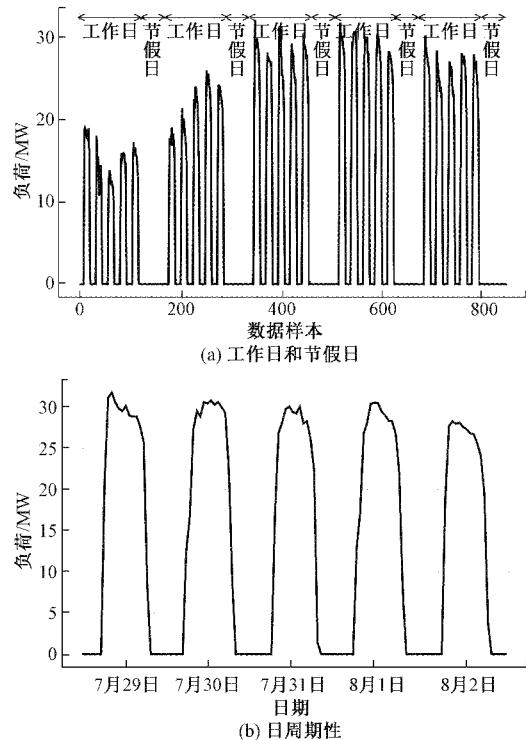


图 2 2019 年 7 月 8 日~8 月 11 日的历史负荷数据曲线图

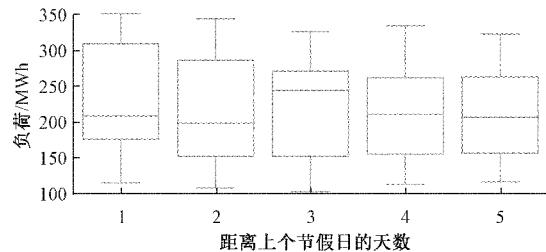


图 3 空调冷负荷按日期类型分类的结果

统设备重启,需要提供更多的冷量来满足用户的需求,负荷也就随之升高。基于此,引入新的日期特征 DPH 作为模型的输入变量,间接反映建筑特性和人员入住率对空调冷负荷的影响。

此外,建立时间序列预测模型需要考虑历史数据,对历史负荷的周期性展开具体分析。图 4 使用自相关函数和偏自相关函数来分析工作时段冷负荷的时间敏感性,可以看出图 4(a) 中自相关函数的拖尾现象及图 4(b) 中偏自相关函数的截尾现象,且出现明显的周期  $T=13$ 。因此在建立提前 1 小时负荷预测模型时,考虑将前 13 个时刻的历史负荷及当前时刻负荷作为输入变量,输出为下一时刻的预测冷负荷,时刻的单位为 h。

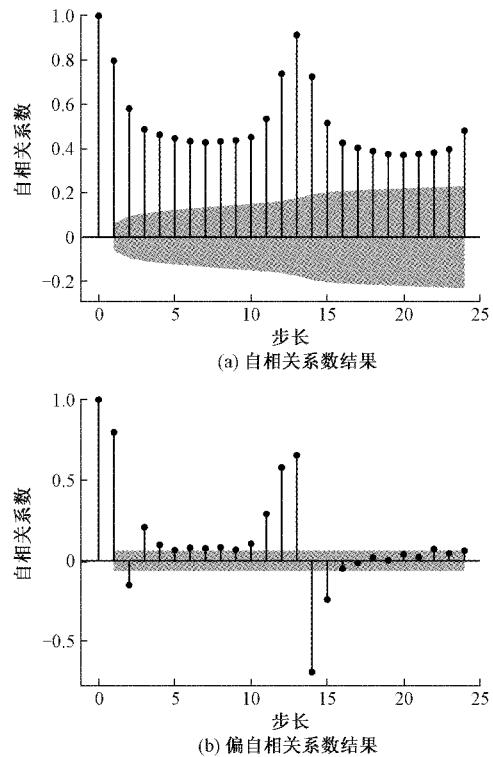


图 4 空调冷负荷的自相关系数和偏自相关系数结果

### 3.3 负荷预测模型建立的流程

基于 RDPG 的提前 1 h 空调冷负荷预测模型建立的流程如下。

1) 对数据进行预处理,作归一化。特别注意的是,对

DPH 特征变量通过独热编码进行标准化。

2) 将预测问题描述为  $MDP: \{S, A, p, r\}$ , 其中状态空间  $S$  表示输入特征集, 用式(9)表示。

$$S = [L_t, L_{t-1}, \dots, L_{t-12}, L_{t-13}, OT_t, DT_t, WS_t, RH_t, DPH] \quad (9)$$

其中,  $L_{t-i}$  表示前  $i$  小时的历史负荷;  $L_t$  表示当前时刻  $t$  的负荷;  $OT_t, DT_t, WS_t$  和  $RH_t$  分别表示当前时刻  $t$  的室外干球温度、露点温度、最大风速及相对湿度。动作空间  $A$  为下一时刻预测负荷的集合, 即  $A = \{L_{t+1}\}; p = (s_{t+1} | s_t, a_t)$  为状态转移概率函数; 奖励函数是评论员用来评估状态-动作值函数  $Q^*(s_t, a_t)$  并指导演员学习新动作的, 即根据预测值与真实值之间的差异大小调整动作, 以更好地预测, 将其定义为  $r_{t+1}$  并用式(10)表示。

$$r_{t+1} = -(y_{t+1} - \hat{y}_{t+1})^2 \quad (10)$$

其中,  $y_{t+1}$  和  $\hat{y}_{t+1}$  分别表示空调冷负荷在  $t+1$  时刻的真实值和预测值。

- 3) 将输入特征集按 7 : 3 分为训练集和测试集。
- 4) 设置折扣率、批处理样本大小、经验回放池记忆单元、迭代次数及参数更新频率。
- 5) 设置学习率, 演员和评论员网络的神经元个数。
- 6) 使用训练集, 训练 RDPG 空调冷负荷预测模型。
- 7) 多次重复试验, 对模型超参数调优。
- 8) 使用测试集, 评价预测模型性能。

#### 4 实验结果及分析

由于引入了新的日期特征 DPH, 首先进行有无 DPH 特征输入的算例对比, 分析节假日对办公建筑的短期空调冷负荷预测的影响; 其次在模型输入特征集相同的前提下, 评估 RDPG 算法与 DDPG 及 LSTM 算法的模型性能, 并进行误差分析, 验证 RDPG 算法在大型空调系统冷负荷预测中的准确性。

表 4 预测模型的评价指标

预测 模型	MAE/MW		RMSE/MW		$R^2(-)$		CV(-)	
	工况 1	工况 2	工况 1	工况 2	工况 1	工况 2	工况 1	工况 2
LSTM	0.945	0.908	1.347	1.237	0.907	0.921	9.77%	8.97%
DDPG	0.994	1.103	1.526	1.315	0.880	0.911	11.07%	9.53%
RDPG	1.042	0.819	1.273	0.976	0.917	0.951	9.23%	7.08%

由表 4 和图 5 可以看出, 工况 2 的评价指标明显优于工况 1。就 RDPG 算法而言, 考虑 DPH 日期特征的预测模型, 4 项评价指标比未考虑 DPH 日期特征的预测模型分别改善了 21.40%, 23.33%, 3.71% 和 23.29%, 表明节假日确实对办公建筑的冷负荷有影响, 将 DPH 作为预测模型输入可以显著提高预测性能。后续的结果分析均在考虑 DPH 作输入特征的前提下进行。

#### 4.1 模型超参数调优结果

深度强化学习算法的最优超参数通常经过反复训练模型获得。经过多次训练, DDPG/RDPG 的通用最优超参数如表 2 所示, 特定最优超参数如表 3 所示。

表 2 通用超参数优化结果

模型	超参数	取值
DDPG/RDPG	折扣率	0.95
	批处理样本大小	128
	经验回放单元大小	1 000 000
	训练迭代次数	1 000
	参数更新频率	0.001

表 3 特定超参数优化结果

模型	超参数	取值
DDPG	学习率	0.001
	演员网络/目标演员网络 神经元个数	17, 100, 50, 1
	评论员网络/目标评论员网络 神经元个数	18, 100, 50, 1
	学习率	0.001
	演员网络/目标演员网络 神经元个数	17, 50, 1
RDPG	评论员网络/目标评论员网络 神经元个数	18, 100, 50, 1
	神经元个数	

#### 4.2 模型性能评估

为验证 DPH 日期特征对负荷预测性能的影响, 基于 3 种算法搭建预测模型, 设置不同工况进行对比分析: 工况 1 不考虑 DPH 日期特征搭建预测模型; 工况 2 考虑 DPH 日期特征搭建预测模型。表 4 为预测模型的评价指标数值, 图 5 为评价指标的结果分布。

对比分析表 4 中的各项评价指标可以发现, RDPG 预测模型的所有评价指标均优于其他两个模型: 相较于 DDPG 而言, 其 4 项评价指标分别改善了 25.75%, 25.78%, 4.39% 和 25.71%; 相较于 LSTM 而言, 其 4 项评价指标分别改善了 9.80%, 21.10%, 3.26% 和 21.07%。对比结果表明, 改进后的 RDPG 算法结合了 DDPG 和 LSTM 的优势, 有效提高了负荷预测的精确度。

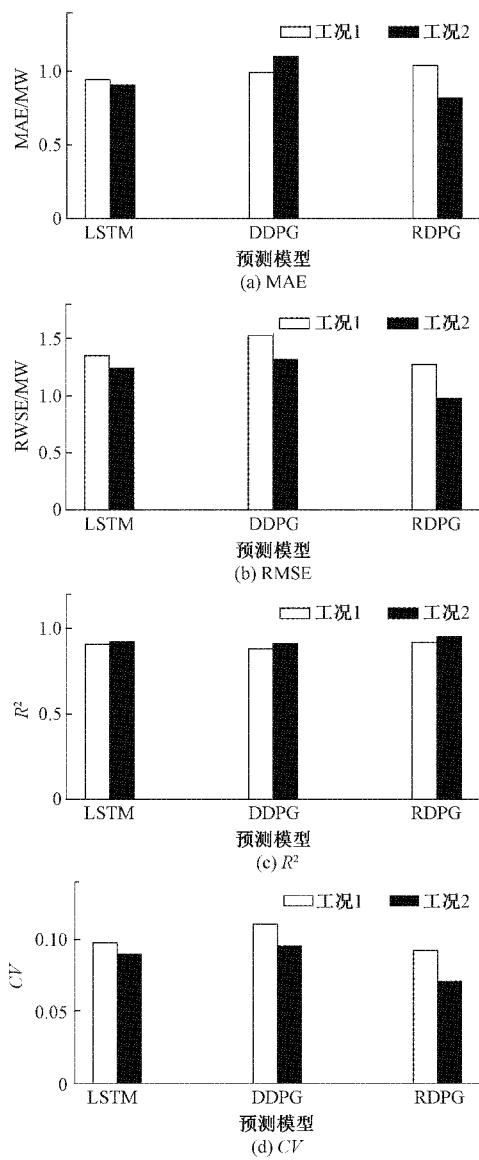


图 5 预测模型的评价指标结果分布

#### 4.3 模型误差分析

模型误差分析主要从两方面展开,一是3种预测模型中预测值与真实值的比较。图6所示为3种模型的预测结果,对角线表示真实值与预测值相等,图6(c)中RDPG模型的预测数据点均匀且集中地分布在对角线两侧,表明预测值接近真实值;图6(b)中DDPG模型的预测数据点大多分布在对角线上侧,表明预测值大于真实值,这是由DDPG存在的过估计问题导致的;图6(a)中LSTM模型的预测数据点较RDPG相对分散,但仍是均匀地分布在对角线两侧,表明LSTM算法较DDPG算法而言在时序预测问题上的准确度更高,但比改进后的RDPG算法准确度低。

二是3种模型的预测值之间的比较。如图7所示,基于典型工作日对预测模型进行对比分析,3种预测模型能

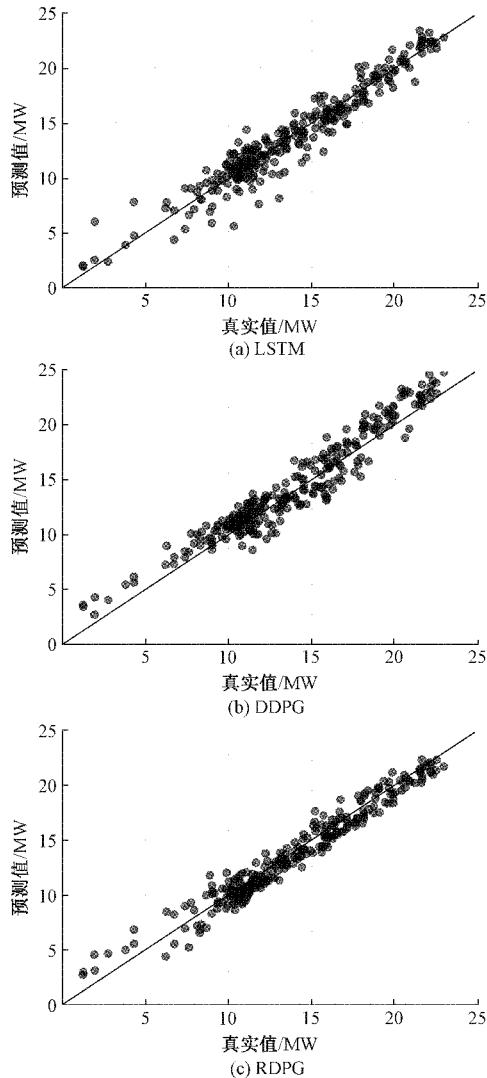


图 6 模型预测结果

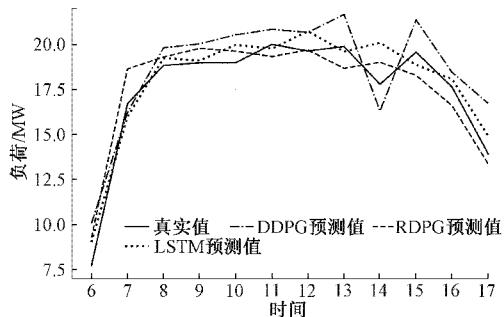


图 7 典型工作日的各模型预测值与真实值曲线

够感知负荷变化趋势,即便是在系统设备早启晚停的陡升陡降时间段,即上午6~7时和下午16~17时,3种模型都可以准确预测负荷的上升和下降趋势。RDPG模型综合了LSTM算法在处理时序问题上的优势和DDPG算法在处理复杂决策问题上的优势,预测值与真实负荷吻合度较高,有效提高了预测精度;由于大型空调系统的不确定性

影响因素过多,单一 LSTM 模型容易陷入局部最优解;DDPG 模型更擅长处理决策问题,且存在过估计现象,所以与真实值误差较大,但在下午 14 时,DDPG 算法准确捕捉到了真实负荷的下降点,考虑将其用于趋势预测。

## 5 结 论

为提高受节假日影响的大型中央空调系统的夏季冷负荷预测精度,分析了节假日对大型中央空调系统的夏季冷负荷造成的差异,提出了新的日期特征 DPH,间接反映了与节假日相关的建筑内部得热和人员入住率对冷负荷的影响,考虑日期特征 DPH 的中央空调负荷预测模型,4 项评价指标分别改善了 21.40%, 23.33%, 3.71% 和 23.29%,表明节假日确实对办公类建筑的冷负荷有影响。使用 LSTM 神经网络替换了 DDPG 算法网络结构中的 MLP,改进后的 RDPG 预测模型用于预测空调冷负荷。在大型空调系统的冷负荷预测问题中,RDPG 预测模型结合 LSTM 算法与 DDPG 算法的优点,预测精度达 0.951;其预测误差值为 7.08%,相较于 LSTM 和 DDPG 分别降低了 21.07% 和 25.71%,验证了改进算法在大型中央空调系统冷负荷预测方面的优越性。在今后的工作中,应当注重对特征工程的研究,并继续改进 DDPG 算法以解决过估计问题。

## 参考文献

- [1] XU G Y, WANG W M. China's energy consumption in construction and building sectors: An outlook to 2100[J]. Energy, 2020, 195: 117045.
- [2] AHMAD M W, MOURSHED M, REZGUI Y. Trees vs neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption[J]. Energy and Buildings, 2017, 147: 77-89.
- [3] ZHANG Y X, LUO H L, WANG C. Progress and trends of global carbon neutrality pledges[J]. Advances in Climate Change Research, 2021, 17(1): 88.
- [4] 刘新宇,赵安军,程仁印,等.基于改进灰色神经网络的商场冷负荷预测模型研究[J].工业控制计算机,2021, 34(8):63-66.
- [5] SHAO M L, WANG X, BU Z, et al. Prediction of energy consumption in hotel buildings via support vector machines[J]. Sustainable Cities and Society, 2020, 57: 102128.
- [6] WANG Z, HONG T Z, PIETTE M A. Building thermal load prediction through shallow machine learning and deep learning[J]. Applied Energy, 2020, 263: 114683.
- [7] 李永丹,马天力,陈超波,等.无人驾驶车辆路径规划算法综述[J].国外电子测量技术,2019,38(6):72-79.
- [8] 张旭中,翟道远,陈俊.基于深度强化学习的木材缺陷图像识别及分割模型研究[J].电子测量技术,2020, 43(17):80-86.
- [9] 康守强,刘哲,王玉静,等.基于改进 DQN 网络的滚动轴承故障诊断方法[J].仪器仪表学报,2021,42(3): 201-212.
- [10] LIU T, TAN Z H, XU C L, et al. Study on deep reinforcement learning techniques for building energy consumption forecasting[J]. Energy and Buildings, 2020, 208: 109675.
- [11] WANG Z, HONG T Z. Reinforcement learning for building controls: The opportunities and challenges [J]. Applied Energy, 2020, 269: 115036.
- [12] SONG R Z, LEWIS F L, WEI Q L, et al. Off-policy actor-critic structure for optimal control of unknown systems with disturbances[J]. IEEE Transactions on Cybernetics, 2015, 46(5): 1041-1050.
- [13] MNIIH V, KAVUKCUOGLU K, SILVER D, et al. Human-level control through deep reinforcement learning[J]. nature, 2015, 518(7540): 529-533.
- [14] QIU C R, HU Y, CHEN Y, et al. Deep deterministic policy gradient (DDPG)-based energy harvesting wireless communications[J]. IEEE Internet of Things Journal, 2019, 6(5): 8577-8588.
- [15] FAN C L, LIAO Y D, ZHOU G, et al. Improving cooling load prediction reliability for HVAC system using Monte-Carlo simulation to deal with uncertainties in input variables [J]. Energy and Buildings, 2020, 226: 110372.

## 作者简介

贾静,硕士研究生,主要研究方向为大型中央空调系统负荷预测。

E-mail: 270215158@qq.com

高文忠(通信作者),博士,教授,主要研究方向为分布式能源系统、冷能利用。

E-mail: wzgao@shmtu.edu.cn