

基于卷积神经网络的数据中心气流温度场快速预测

Fast Prediction of Airflow Temperature Field in Data Centers
Based on Convolutional Neural Networks

任波¹,贺伟²,罗惠恒³,刘育策³,王梦³,章文恺⁴(1. 中国长江电力股份有限公司,湖北武汉 430000;2. 三峡电能有限公司,湖北武汉 430000;3. 中国长江三峡集团有限公司,湖北武汉 430063;4. 浙江大学制冷与低温研究所,浙江杭州 310027)
Ren Bo¹,He Wei²,Luo Huiheng³,Liu Yuce³,Wang Meng³,Zhang Wenkai⁴(1. China Yangtze Power Co., Ltd., Wuhan 430000, China;2. Three Gorges Electric Energy Co., Ltd., Wuhan 430000, China;3. China Three Gorges Corporation, Wuhan 430063, China;4. Institute of Refrigeration and Cryogenics, Zhejiang University, Hangzhou 310027, China)

摘要:

为实现数据中心制冷系统精细化节能,针对传统CFD计算耗时及现有模型空间利用不足的问题,提出一种基于卷积神经网络的气流温度场预测框架。该方法通过空间特征图构建输入空间特征,利用卷积神经网络对空间特征进行提取、编码,使用人工神经网络融合工况信息与空间信息,并通过反卷积神经网络实现快速预测。经某大型数据中心机房的温度场数据验证,该方法平均绝对误差为0.312℃,可以为数据中心机房的精细化节能控制提供更可靠的气流组织。

关键词:

数据中心;气流组织;数据驱动模型;卷积神经网络;人工神经网络

doi:10.12045/j.issn.1007-3043.2026.03.014

文章编号:1007-3043(2026)03-0074-06

中图分类号:TU834.3

文献标识码:A

开放科学(资源服务)标识码(OSID):



Abstract:

To achieve refined energy-saving control of data center refrigeration systems, it proposes a convolutional neural network-based framework for predicting airflow and temperature fields, addressing the limitations of time-consuming traditional CFD calculations and the insufficient utilization of spatial information in existing models. The proposed method constructs input spatial features through spatial feature maps and utilizes a CNN to extract and encode these features. Subsequently, an artificial neural network is employed to fuse operational parameters with spatial information, while a deconvolutional neural network is implemented to achieve rapid prediction. Validated by temperature field data from a large-scale data center, the results demonstrate that the method achieves a mean absolute error of 0.312 °C. This approach provides more reliable airflow organization for the refined energy-saving control of data center rooms.

Keywords:

Data center; Airflow organization; Data-driven methods; Convolutional neural networks; Artificial neural networks

引用格式:任波,贺伟,罗惠恒,等. 基于卷积神经网络的数据中心气流温度场快速预测[J]. 邮电设计技术,2026(3):74-79.

0 引言

随着信息化社会飞速发展带来的计算和存储资源需求的激增,近年来数据中心的能耗需求显著上

升,已成为全球能源消耗的重要组成部分^[1-2]。2023年全年,我国数据中心耗能量达到1500亿kWh,同比增长15.4%,占全社会用电量的1.63%^[3]。在我国“2030碳达峰”和“2060碳中和”的双碳大目标下,提升数据中心的运行能效,实现数据中心的节能减排至关重要。当前数据中心的能耗主要由IT设备、冷却系统、配电照明等辅助系统组成^[4]。其中,将近50%的能耗用于制冷系统,通过提供冷气流对IT设备进行降温^[5]。

基金项目:中国长江电力股份有限公司(Z342302013)

通讯作者:章文恺,12127054@zju.edu.cn

收稿日期:2026-02-11

因此,数据中心制冷系统拥有巨大节能潜力,制定合理的制冷系统控制策略,在保证数据中心安全可靠运行的前提下实现高效节能,是实现数据中心节能降碳的关键一环^[6]。

数据中心制冷系统的控制通常基于机房现场布置的传感器,通过传感器读值调整温度设定点,进行反馈控制^[7]。然而,数据中心的温度分布往往不均匀,使用实际传感器测量温度时,其效果受到具体位置的限制。因此,获取数据中心气流组织的完整温度分布,从而全面对机房整体进行气流组织的优化,是精细化节能控制系统运行的基础与前提^[8]。

目前,通常基于计算流体力学(Computational Fluid Dynamics, CFD)方法进行数据中心气流组织的计算。然而,CFD的计算过程通常非常复杂,涉及基于大量网格节点处理离散的微分方程,这使得CFD的计算过程往往非常耗时,尤其是在数据中心这类需要对高分辨率或复杂几何形状流场进行模拟的情况下^[9]。因此,在数据中心场景中,CFD方法往往无法满足实时控制的需求。

相比之下,数据驱动的方法可以利用已有的实验或仿真数据来建立预测模型,无需复杂的物理求解过程,一个经过良好训练的模型就可以非常快速地进行准确预测,能够满足实时控制对于计算速度的需求^[10]。例如,殷佳辉等人^[11]基于CFD数据集,使用Elman神经网络、RBF神经网络和SVR支持向量回归机,对数据中心稳态运行情况下的不同机柜负载率的空调回风温度进行快速预测,但该研究仅停留在对回风温度的估计上。黄金森等人^[12]研究了基于SVR的数据中心空调系统瞬态热参数预测,建立针对空调失效极端工况下的快速温度预测模型,同样仅进行点估计,未考虑温度分布问题。为实现温度分布的快速预测,许俊等人^[13]采用卷积神经网络配合CFD数据,实现了一种可以快速预测数据中心机房某一特定截面的温度分布的方法,平均绝对误差(Mean Absolute Er-

ror, MAE)为3.12 °C。Dai^[14]等人提出了一种基于POD和CFD耦合的新型多尺度模型,用于预测数据中心从房间尺度到芯片尺度的热和流体特性,对房间气流组织预测的最大相对偏差为7.21%。Fang^[15]等人使用深度神经网络(DNN)来预测温度数据,MAE为3.51 °C。上述研究初步证明了数据驱动方法在数据中心机房气流组织快速预测上的可行性,但是大型数据中心机房是数据中心产业的耗能主体,其流场更加复杂,如何实现大型数据中心机房各横向截面温度的快速高精度预测,仍然有待探究。

针对上述问题,本文提出一种基于改进卷积神经网络框架的数据中心机房温度场预测模型。相较于现有的方法,本框架结合了卷积神经网络的空间特征提取能力以及人工神经网络融合高度非线性关系的能力,使用卷积神经网络处理空间数据,使用人工神经网络处理运行工况数据,旨在快速准确地预测大型数据中心多平面温度场。

1 模型建立及描述

图1所示为本研究所提出的数据中心气流组织预测模型的结构,主要包含4个模块,分别为特征工程模块、卷积模块、人工神经网络模块以及反卷积模块。

1.1 特征工程模块

特征工程模块将平面离散为正交的网格,并给每个网格赋一个标签值,代表该区域的空间属性,例如在本实验中,过道、服务器等空间位置将获得不同的赋值。通过该步骤,二维平面图片及其包含的信息将被转化为神经网络可接受的输入。特征工程模块示意如图2所示。

1.2 卷积模块

卷积神经网络(Convolutional Neural Networks, CNN)是一类专门用于处理空间数据结构的深度学习模型,其核心构建块包括卷积层和池化层。卷积层通过应用多个卷积核在输入数据上进行卷积操作,能够




图1 基于卷积神经网络的数据中心气流组织预测模型示意




图2 特征工程模块示意

有效地捕捉空间中的局部特征。池化层则通过下采样来降低数据的维度,减少计算量并防止过拟合。通过多层卷积和池化操作,CNN能够逐步提取不同尺度的空间特征,并用于预测任务。

图3展示了卷积核的计算原理。通过核函数与输入数据间的运算获得单个输出数据,通过核函数在输入数据上的移动,获得输出数据不同的位置结果。计算过程如式(1)所示。

$$y = A_{in}A_{kernel} + B_{in}B_{kernel} + C_{in}C_{kernel} + D_{in}D_{kernel} \quad (1)$$

其中, A_{in} 、 B_{in} 、 C_{in} 、 D_{in} 为输入数据A、B、C、D的位置数值, A_{kernel} 、 B_{kernel} 、 C_{kernel} 、 D_{kernel} 为卷积核A、B、C、D的位置数值。

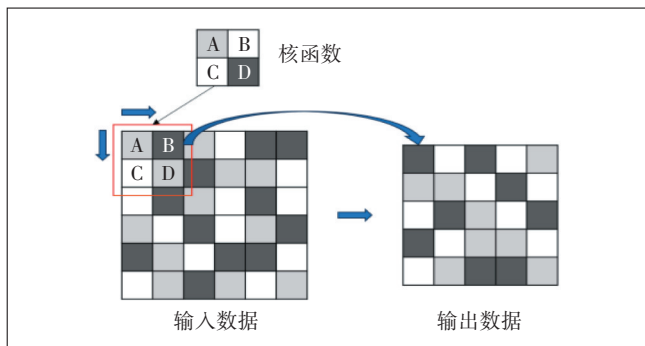


图3 卷积核计算原理示意

在本文提出的卷积神经网络框架中,输入为经过特征工程模块处理后的多维向量,用于表征机房的空信息。通过卷积层对该向量进行处理,可有效捕捉机房的潜在空间特征。最终,输出数据将作为人工神经网络模块的输入。

1.3 人工神经网络模块

人工神经网络(Artificial Neural Networks, ANN)由大量人工神经元组成,这些神经元通过权重连接形成复杂的网络结构。网络中每个神经元接收多个输入信号,并通过加权求和及激活函数计算输出信号,从而实现信息的非线性变换。

图4给出了ANN结构示意图,其由1个输入层、若干

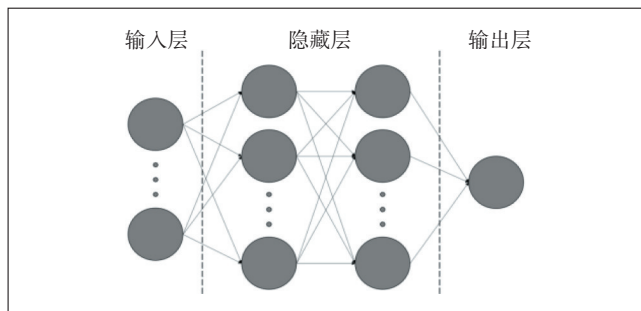


图4 典型ANN结构示意图

隐藏层与1个输出层构成。

输入层接收输入向量,输出层输出一维或多维向量。输入层与输出层之间的神经元被称为隐藏层,接收多个输入信号,并通过加权求和和激活函数计算输出信号,从而实现高维非线性关系的拟合。相邻神经元间的连接权重可调整。输出向量通过式(2)进行加权计算。

$$y = W_{out}h + b_{out} = W_{out}\varphi(W_{hidden}x + b_{hidden}) + b_{out} \quad (2)$$

其中, W_{out} 与 W_{hidden} 为输出层和隐藏层中神经元间连接权重, b_{out} 与 b_{hidden} 为输出层与隐藏层偏置项, φ 为激活函数, x 为输入向量。

在本文提出的网络结构中,输入层为卷积网络输出向量与工况变量(空调温度、机柜功率、平面高度)相连接后的多维向量,用于表征系统空间信息、工况信息的整合结果。通过隐藏层将该向量进行高维非线性映射,可以得到融合后的全局特征向量,作为反卷积模块的输入。

1.4 反卷积模块

反卷积的过程可以看作是卷积的逆向过程,包括上采样和卷积操作,上采样阶段通过插入额外的像素位置和填充来扩展特征图的尺寸,本研究采取最近邻上采样方法,如式(3)所示。

$$Y(i, j) = X\left(\left\lfloor \frac{i}{r} \right\rfloor, \left\lfloor \frac{j}{r} \right\rfloor\right) \quad (3)$$

其中, $Y(i, j)$ 表示输出特征图的像素坐标; $\lfloor \cdot \rfloor$ 表示向下取整操作; r 为上采样的比例因子,为正整数; X 表示输入图像,即对于输出特征图中的任一像素 $Y(i, j)$,其值由输入特征图 X 中最近邻的像素值决定。

经过上采样得到特征图通过卷积解码流场特征的隐变量,卷积计算公式与式(1)相同。在本研究中,反卷积模块接收由ANN输出的全局特征向量,通过卷积的逆向运行预测目标流场的温度分布。

1.5 模型训练与性能验证

基于上述卷积神经网络的机房气流组织代理模型,通过反向传播算法调整模型的权重和偏置,以最小化损失函数,实现模型训练。本研究中,损失函数采用均方误差(mean square error, MSE),计算如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

其中, n 是样本的数量, y_i 是第 i 个样本的实际值, \hat{y}_i 是第 i 个样本的预测值。

训练完毕的代理模型在测试集中进行模型性能评估,本研究采用 MAE、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 与判定系数 (R^2) 作为模型评价指标,计算如下:

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

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (6)$$

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

其中, n 是样本的数量, y_i 是第 i 个样本的实际值, \hat{y}_i 是第 i 个样本的预测值, \bar{y} 是样本的平均值。

2 实例分析

2.1 实例数据

本研究选取湖北某大型数据中心机房作为研究对象,对所提出的气流组织预测框架进行性能验证。图5给出了该数据中心机房的示意,该机房长29 m,宽28 m,高5.5 m,其中设有10个微模块,每个微模块包




图5 案例数据中心机房示意

含27~28个机柜,空调采用风墙AHU水平弥散式送风,机柜侧热通道封闭。AHU侧面将冷风弥散送至冷通道,不设架空地板,冷风带走服务器机柜内的热量后从机柜后部排至封闭热通道,再通过热回风道(吊顶)回至空调机组后部回风口。通过CFD软件模拟该机房不同空调设定温度及服务器功率下数据中心的温度分布,即可得到用于训练深度学习模型的CFD仿真数据集。

本研究中,机柜功率在1~6 kW间变化,空调设定温度在18~27 °C间变化。本研究采取固定工况参数变化步长,通过组合遍历的方式实现多组仿真,其中机柜功率的变化步长为1 kW(即共有6种功率状态),空调设定温度的变化步长为1 °C(即共有10种温度状态),最终可得到60组不同工况下的温度场分布结果。对于每一个三维样本,在高度方向上每隔0.5 m截取一个二维平面的结果(即共有12个平面状态),最终共计获得720个二维温度场样本,某工况下不同高度平面的温度场分布情况如图6所示。其中,2 m及以下为机柜所在区域,2~3.5 m为机柜上方、吊顶下方的风道区域,3.5 m以上为吊顶上部的回风区域。对于得到的仿真数据,本研究采取最近邻插值重采样方法,将不规则网格温度场数据转换为规则的正交网格温度场数据,使其能够被卷积神经网络处理,为确保转换后的温度场数据仍能保留原始流场特征,本研究的重采样分辨率选取0.1 m,即最终得到的温度场分辨率为290×280。最终,共得到720个二维温度场标签数据样本,将其随机划分为90%的训练集(648个样本)和10%的测试集(72个样本),所提出的模型在训练集中

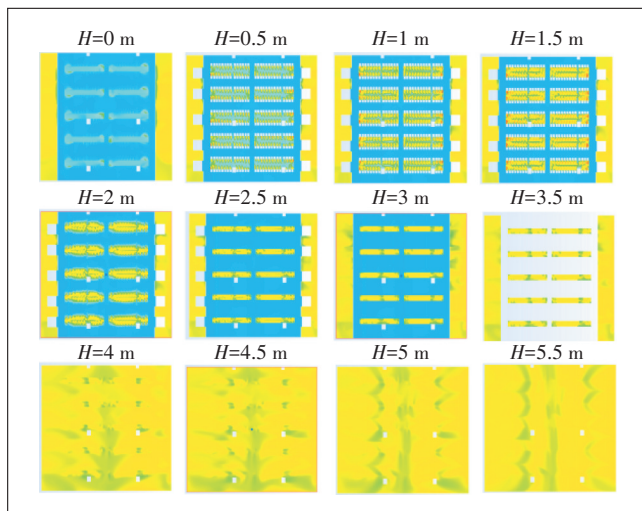


图6 某工况下不同高度平面的温度场分布情况示意

进行训练,在测试集上验证模型的性能。

2.2 空间特征图表征结果

如图7所示,利用空间特征图转换方法,将案例机房不同高度平面的几何分布情况转换为用于卷积模块输入的空间特征图,其中,气流组织所在的流域网格单元被赋予标签值1(图7中黑色部分),设备、建筑实体等非流域网格单元被赋予标签值0(图7中白色部分)。本研究中,空间特征图分辨率与温度场重采样分辨率保持一致,即空间特征图分辨率为290×280,每个网格单元对应0.1 m×0.1 m的矩形空间。

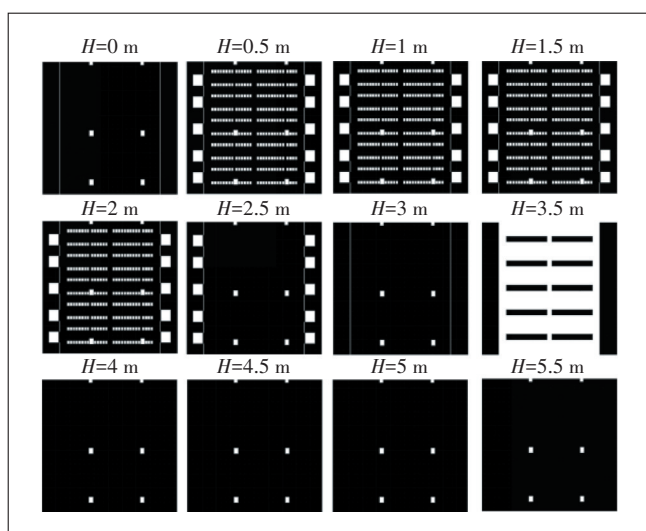


图7 案例数据中心不同高度平面的空间特征图示意

2.3 气流组织预测模型训练结果

本研究选取了温度点预测任务中主流的ANN模型作为对比。ANN模型的输入与本研究所提出气流组织预测框架中的人工神经网络层一致,而所提出的模型则进一步引入空间特征。为确保模型训练效率和预测性能,在模型训练过程中,所有输入、输出数据均在各自的变量维度上采取0~1标准化算法进行归一化,如式(8)所示。

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

其中, x 为原始数据, x_{\min} 为原始数据中的最小值, x_{\max} 为原始数据的最大值, x_{norm} 为归一化后的数据。

为了确保模型均获得最佳的性能表现,采用网格搜索算法对所提出框架以及ANN模型进行超参数寻优。基于CNN的气流组织预测模型的优化结果如下:卷积层数与反卷积层数为2层,每层采取3×3大小的卷积核,步幅和填充为1,卷积层第1、2层的通道数分

别为32、64,反卷积层第1、2层的通道数分别为64、32;人工神经网络层层数为2,隐藏层神经元数量为1 024;模型的学习率为0.000 1。ANN模型的优化结果如下:网络的隐藏层数为6,其中第1、2隐藏层的神经元数量分别为64、256,剩余隐藏层的神经元数量为1 024;模型学习率为0.000 1。

最终,模型在训练集中进行训练,并在测试集上计算预测精度,模型训练过程的损失函数曲线如图8所示。从图8可以看出,所提出的基于CNN的预测模型在训练集中快速收敛并趋于平稳,而ANN的损失函数呈阶梯式下降,且最终损失仍较大。模型在测试集中的性能对比如表1所示,引入CNN进行空间特征提取和编码解码的预测模型的性能表现远优于ANN,而不具备空间特征处理能力的ANN模型并不适用于温度场预测,无法为气流组织控制提供有效信息。

2.4 结果分析与讨论

为进一步说明CNN—ANN—DCNN框架的性能,随机选取了测试集中不同高度平面下模型预测温度场与数据预处理后的真实温度场进行对比(见图9)。

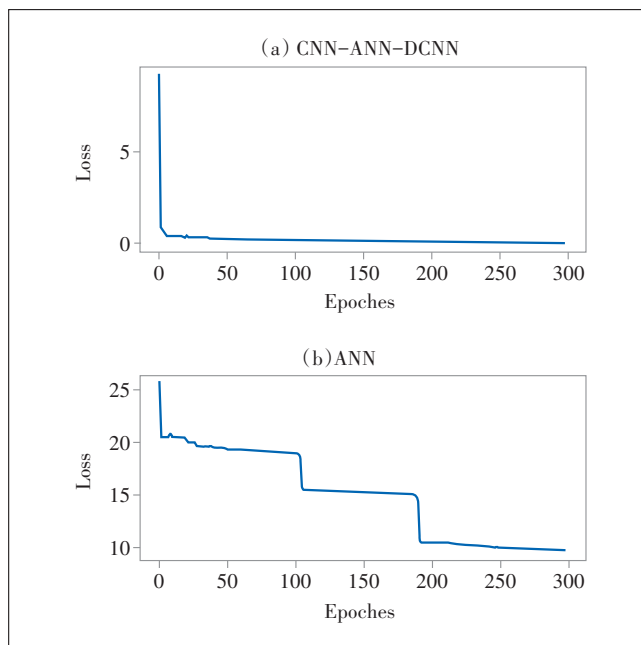


图8 模型在训练过程中的损失曲线

表1 模型在测试集上的精度对比

模型	MAE/°C	MAPE	R ²
CNN-ANN-DCNN	0.312	1.195%	0.984
ANN	3.681	14.19	-3.299

从图9可以看出,在不同机房高度平面、不同机房运行工况下,所提出的预测框架均能够对温度场的整体分布情况进行准确的预测。上述结果验证了引入如CNN等具备空间特征处理能力的深度学习模型,能够显著提升数据驱动方法在气流组织空间预测方面的能力。另一方面,该模型在测试集中的平均运行时间为0.04 s/样本,其计算速度是常规CFD方法的千倍以上,符合实时控制对于数据反馈的需求。

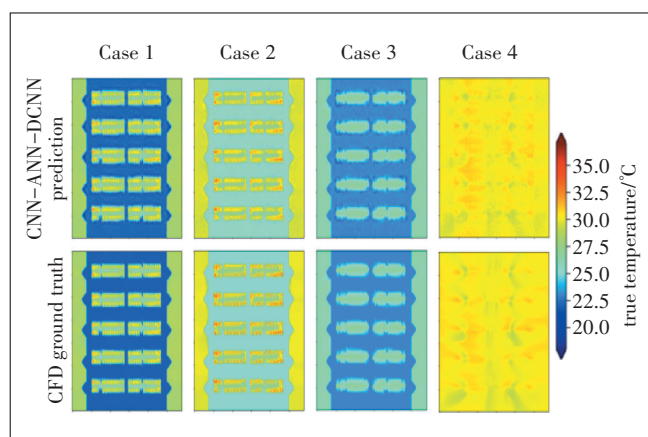


图9 基于CNN的气流组织预测模型结果可视化

3 结论与展望

针对数据中心冷却系统的实时节能控制需要快速获得气流组织分布的问题,本研究提出一种基于卷积神经网络的数据中心机房气流温度场预测框架,通过CNN对空间特征进行编码,通过ANN对工况信息以及位置信息进行编码,同时融合来自CNN编码后的空间特征,并通过DCNN预测目标温度场。该方法在某大型数据中心机房进行了验证,结果表明所提出的模型经训练后,能够准确快速地对不同运行工况、不同高度平面的机房温度场进行预测。对比结果表明,引入能够进行空间特征处理的技术对于数据驱动的气流组织场预测方法具有关键作用。

本研究初步证明了基于卷积神经网络的数据中心气流温度场预测方法的可行性,然而,温度场实际上是一个三维空间场,仅对固定的高度截面预测的方法在模型训练时无法考虑到垂直方向的气流作用关系,因此预测精度仍有提升空间。同时,本研究仅在固定空间布局的机房中实现了不同运行工况下的预测,可以大幅提升预测模型的通用性,降低模型的训练成本。

参考文献:

- [1] 胡奇,陈华强.某数据中心热环境优化研究[J].江苏通信,2023,39(6):85-89.
- [2] 贺晓,邢殿辉,刘湃,等.数据中心空调系统AI调优节能应用[J].邮电设计技术,2023(12):1-6.
- [3] 远景科技集团,合盈数据,中国信通院云计算与大数据研究所.数据中心全生命周期绿色算力指数白皮书[R/OL].[2025-08-09].<https://www.fxbaogao.com/detail/4424610>.
- [4] 黄海.基于云计算的通信数据中心能耗优化探究[J].大众标准化,2024(9):168-170.
- [5] ZHANG X, LINDBERG T, XIONG N, et al. Cooling energy consumption investigation of data center IT room with vertical placed server [J]. Energy Procedia, 2017, 105: 2047-2052.
- [6] 陆翰涛,黄赞,陈强. AI技术在数据中心制冷系统智能节能研究和应用[J]. 上海节能, 2024(4): 667-672.
- [7] 林敏鑫. 基于STM32的数据中心暖通空调自动控制系统设计[J]. 电子技术与软件工程, 2022(3): 91-94.
- [8] 张博,廖炜铨,李学智,等. 数据中心中机柜出风温度的快速模拟[J]. 西安工程大学学报, 2023, 37(5): 1-9, 38.
- [9] 苗益川,朱兵,岳天亮,等. 数据驱动的数据中心气流组织预测综述[J]. 计算机时代, 2023(4): 96-100.
- [10] KOCHKOV D, SMITH J A, ALIEVA A, et al. Machine learning-accelerated computational fluid dynamics [J]. Proceedings of the National Academy of Sciences of the United States of America, 2021, 118(21): e2101784118.
- [11] 殷佳辉,朱兵,张一鸣,等. 基于机器学习的数据中心稳态热参数预测[J]. 计算机时代, 2023(11): 71-75, 78.
- [12] 黄金森,朱兵,张一鸣,等. 基于SVR数据中心空调系统瞬态热参数预测[J]. 智能计算机与应用, 2023, 13(11): 161-165.
- [13] 许俊,程序,胡孝俊,等. 基于人工智能算法的数据中心机房气流组织温度预测研究[J]. 邮电设计技术, 2022(12): 52-56.
- [14] DAI Y J, ZHAO J, ZHANG X L, et al. Thermal full-field prediction of an air-cooled data center using a novel multi-scale approach based on POD and CFD coupling [J]. Energy and Buildings, 2024, 307: 113992.
- [15] FANG L L, XU Q S, LI S J, et al. Temperature prediction in data center combining with deep neural network [J]. Applied Thermal Engineering, 2024, 244: 122571.

作者简介:

任波,毕业于重庆大学,高级工程师,硕士,主要从事电气一次技术研究工作;贺伟,毕业于武汉大学,高级工程师,硕士,主要从事水利水电、综合能源技术研究工作;罗惠恒,毕业于武汉大学,高级工程师,硕士,主要从事数字化管理研究工作;刘育策,毕业于西安交通大学,工程师,博士,主要从事能源动力系统仿真优化研究工作;王梦,毕业于华中科技大学,硕士,主要从事建筑能源系统研究工作;章文恺,浙江大学博士在读,主要从事建筑环境快速仿真研究工作。