

基于改进秃鹰搜索算法优化门控循环单元的短期建筑冷负荷预测模型

于军琪, 代俊伟, 权 炜, 刘海燕

(西安建筑科技大学 建筑设备科学与工程学院, 西安 710055)

摘要: 准确地预测建筑冷负荷对空调系统节能优化控制具有重要作用, 因此提出一种改进秃鹰搜索算法 (BES) 优化门控循环单元 (GRU) 的短期冷负荷预测模型; 首先采用完全噪声辅助聚合经验模态分解 (CEEMDAN) 算法, 将建筑冷负荷数据分解为不同频率的分量, 采用随机森林结合递归特征消除法为不同频率的分量选取对应的特征; 最后采用改进 BES 算法对 GRU 模型进行参数寻优, 针对 BES 算法不足进行改进, 引入 Sobol 序列初始化种群、采用非线性控制因子平衡 BES 算法搜索能力和自适应 t 分布策略提升算法寻优能力; 实验结果表明, 与 GRU 和改进 BES 算法优化后的 GRU 相比, 提出的预测模型均方根误差下降 34.27, 22.41、平均百分比误差下降 2.72%, 2.63%、平均绝对误差下降 27.25, 25.26; 相较于其他预测模型, 提出的预测模型具有更高的预测准确度, 在实际工程应用中更具优势。

关键词: 冷负荷预测; 经验模态分解; 秃鹰搜索算法; 超参数寻优; 门控循环单元

Short-term Building Cooling Load Prediction Model Based on Improved Bald Eagle Search Algorithm for Optimizing Gated Recurrent Unit

YU Junqi, DAI Junwei, QUAN Wei, LIU Haiyan

(School of Building Services Science and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: It plays an important role to accurately predict the cooling load of buildings in energy-saving optimization control of air conditioning systems, therefore, an improved bald eagle search (BES) algorithm is proposed to optimize the short-term cooling load prediction model of gated recirculation units (GRU); Firstly, the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) algorithm is used to decompose the building cooling load data into components with different frequencies, and the random forest combined with the recursive feature elimination method is used to select the corresponding features for the components with different frequencies; Finally, the improved BES algorithm is used to optimize the parameters of the GRU model. With the shortcomings of the BES algorithm, the Sobol sequence is introduced to initialize the population, adopting the nonlinear control factor to balance the search capability of the BES algorithm, and the adaptive t-distribution strategy to enhance the algorithm's optimization ability; Experimental results show that compared with the GRU and GRU with improved BES algorithm, the proposed prediction model decreases the root mean square error by 34.27, 22.41, the average percentage error by 2.72%, 2.63%, and the average absolute error by 27.25, 25.26; Compared with other prediction models, the proposed prediction model has a higher prediction accuracy, which is more advantageous in practical engineering applications.

Keywords: cooling load prediction; empirical mode decomposition; BES optimization algorithm; hyperparameter optimization; GRU

0 引言

建筑行业是全球能源消耗的主要部分, 特别是大型公共建筑中的集中空调系统消耗的能源最多, 节能潜力巨大^[1]。准确的冷负荷预测不仅有助于规划集中空调系统的运行周期和制定相应的节能策略, 还能为建筑能源管理中

的任务奠定基础^[2]。

近年来产生大量关于建筑冷负荷预测的研究方法, 目前主要分为两类: 基于物理模拟和数据驱动建模方法^[3]。物理模拟通过建筑能源模拟软件, 基于热力学原理来预测建筑冷负荷, 但由于建筑结构复杂获得准确的参数困难, 难以精确模拟实际工程场景^[4]。数据驱动方法忽略了建筑

收稿日期: 2023-10-25; 修回日期: 2023-12-05。

基金项目: 国家重点研发计划(2022YFC3802700)。

作者简介: 于军琪(1969-), 男, 博士, 教授, 博士生导师。

权 炜(1975-), 男, 博士, 副教授, 硕士生导师。

引用格式: 于军琪, 代俊伟, 权 炜, 等. 基于改进秃鹰搜索算法优化门控循环单元的短期建筑冷负荷预测模型[J]. 计算机测量与控制, 2024, 32(12): 191-200.

设计细节和建筑内部热量传递规律,使建模过程较为简单。同时随着建筑自动化系统的发展,数据采集更加简便,数据驱动模型的应用成本更低、适用范围更广。综上所述,数据驱动方法在实际工程中更具优势。

早期数据驱动方法主要采用统计模型,例如多元线性回归、高斯过程回归和差分整合移动平均自回归模型等^[5]。这些统计模型在线性序列建模方面表现出色,但它们依赖于参数假设检验,因此在复杂情境下的预测效果有限。目前人工神经网络(ANN)在预测领域内备受瞩目,在建筑能源预测中47%的预测模型都是基于ANN^[6]。然而,ANN结构简单,无法有效地捕捉和利用时间序列数据中的先前信息。为了解决这一问题,循环神经网络(RNN)被引入,它能够循环递归地挖掘时间序列数据中的有效信息^[7],但RNN在处理时间跨度较长的序列数据上会出现梯度消失和梯度爆炸的问题。为改进RNN的局限性,1997年长短期记忆网络(LSTM)被提出,该模型更适合处理时间序列中的长期依赖关系。但是LSTM的结构复杂,计算时间长^[8],不利于实际应用。

GRU是LSTM的一种变体^[9],将LSTM的“遗忘门”“输入门”“输出门”简化为GRU的“更新门”和“重置门”,使所训练的参数变少,网络结构更简单。GRU在不损失预测精度的情况下具有更快的运行速度,并且在许多预测问题中表现出良好的性能^[10]。文献[11]使用RNN,LSTM和GRU预测建筑能耗,实验结果表明GRU的预测性能最好。文献[12]研究对住宅建筑的中短期负荷预测,使用GRU实现更高准确度。文献[13]采用神经网络构建冷负荷预测模型,实验结果表明,GRU在冷负荷预测方面优于LSTM。以上研究证明了GRU在冷负荷预测中的有效性,但GRU的超参数影响预测性能,如何设置超参数将是一个难题。

目前,许多学者采用优化算法来确定神经网络超参数,例如粒子群算法^[14],鲸鱼算法^[15],灰狼优化算法^[16]等。文献[17]采用改进正弦算法优化GRU的学习率和隐藏层神经元数量,提高模型的预测准确性。文献[18]采用改进麻雀算法对GRU的隐藏层神经元数量、迭代次数和学习率进行优化,降低了RMSE和MAE。这些文献研究表明,采用优化算法对GRU超参数优化可以提高模型的预测精度。然而,智能优化算法本身寻优机制也存在不足,如早熟收敛、易陷入局部最优等问题,限制了优化算法结合预测模型在性能上的进一步提升空间。

许多学者在预测模型中加入分解技术提高预测精度^[19-21]。经验模式分解(EMD)通过分析数据的时间尺度特征进行信号分解,无需选取基函数,被认为是有效处理非线性和非平稳数据的一种分解方法,但EMD算法存在由间歇性信号引起的模式混合问题,导致破坏实际信号的变化趋势。为解决这一问题,CEEMDAN算法在EMD算法的每个分解阶段都加入自适应噪声,可以有效改善分解结果并减少计算成本^[22]。文献[23]采用样本熵对CEEM-

DAN分解后的数据序列进行重构,成功解决分量序列之间的自相关问题,然后运用LSTM对数据分量进行预测。文献[24]采用CEEMDAN将原始建筑能耗数据分解为多个不同频率分量。然后用RF预测高频分量,用LSTM预测其余分量,实验结果证明加入分解技术后有效提升模型预测准确度。这些研究进一步强调了分解技术对提升模型预测精度的重要性。

本文根据上述的研究问题,提出一种混合模型来预测建筑冷负荷,所提出的混合模型采用每种方法的优点来克服彼此的局限性。最后,通过均方根误差(RMSE)、平均绝对百分比误差(MAPE)和平均绝对误差(MAE)这3个评价指标验证本文提出的混合模型的有效性。本文研究的贡献总结如下:

1) 为了降低数据的波动性,提高数据的利用率。本文采用CEEMDAN算法将原始冷负荷数据分解成若干个不同频率的分量,为不同频率分量选取对应的特征。再使用GRU对每个分量进行预测,并整合每个分量的预测结果,以获得最终的预测结果。

2) 针对使用优化算法优化GRU超参数训练时间长,容易陷入局部最优的问题,选择寻优能力强的秃鹰搜索算法(BES)。并且针对BES的缺点,本文采用3种改进策略,提出IBES将其应用在GRU超参数优化中,提高模型的性能并调整网络的非线性程度。

3) 提出一种CEEMDAN-IBES-GRU混合预测模型。分析CEEMDAN对冷负荷数据分解的有效性。通过与其他优化算法的性能分析比较,证明IBES在搜索速度和能力方面的优势。结合实际案例,通过与其他模型比较,验证本文模型在冷负荷预测方面的准确性。

1 预测模型的建立方法

1.1 完全噪声辅助聚合经验模态分解

CEEMDAN将非线性和非平稳序列分解成几个相对平稳的分量。这些分量将被命名为本征模函数 IMF_k ,本文定义 $x(n)$ 为建筑原始冷负荷数据序列, $E_j(\cdot)$ 是经过EMD分解后的第 j 个分量, I 为冷负荷数据集的样本总数。CEEMDAN算法分解步骤如下:

1) 在原始序列 $x(n)$ 中添加幅值为 ϵ_0 的白噪声 $w^i(t)$ 得到:

$$x^i(t) = x(n) + \epsilon_0 w^i(t) \quad (1)$$

2) 使用EMD算法对 $x^i(t)$ 进行 I 次分解,通过计算均值得到第一个模态分量,计算公式如下:

$$\widetilde{IMF}_1(n) = \frac{1}{I} \sum_{i=1}^I IMF_1^i(n) = \overline{IMF}_1(n) \quad (2)$$

3) 在第一个阶段($j=1$)计算第一个唯一的余量信号,计算公式如下:

$$r_1(n) = x(n) - \widetilde{IMF}_1(n) \quad (3)$$

4) 将实验重复 i 次,在每次实验过程中,对信号 $r_1(n) + \epsilon_1 E_1[w^i(n)]$ 进行分解,当得到第一个EMD模态分量时

停止。此时得到第二个模态分量:

$$\widetilde{IMF}_2(n) = \frac{1}{I} \sum_{i=1}^I E_1 \{r_1(n) + \varepsilon_1 E_1[\tau^i(n)]\} \quad (4)$$

5) 在剩下的阶段中, 计算第 k 个余量信号, 得到:

$$r_k(n) = r_{k-1}(n) - \widetilde{IMF}_k(n) \quad (5)$$

6) 继续将实验重复 i 次, 在每次实验过程中, 对信号 $r_k(n) + \varepsilon_i E_k[\tau^i(n)]$ 分解, 当得到第一个 EMD 模态分量时停止, 此时得到第 $k+1$ 个模态分量:

$$\widetilde{IMF}_{k+1}(n) = \frac{1}{I} \sum_{i=1}^I E_1 \{r_k(n) + \varepsilon_i E_k[\tau^i(n)]\} \quad (6)$$

7) 重复 5) 至 7) 以获得所有 IMF 分量, 直到余量信号是单调函数并且不能被 EMD 分解。原始数据的最终分解结果可以表示为:

$$x(n) = \sum_{k=1}^K \widetilde{IMF}_k + R(n) \quad (7)$$

1.2 随机森林特征选择

目前对特征的选取方法常用相关系数法, 例如皮尔逊、斯皮尔曼和肯德尔相关系数等, 这些方法在统计分析中常用来衡量两个变量之间的线性或单调关系的强度。但这些方法对模型中的非线性的变量效果较差, 而且难以避免变量之间的相互作用, 导致不能准确计算相关系数。随机森林 (RF) 作为一种集成学习算法^[25], 被广泛应用于分类和回归预测模型中, 该算法能计算出各个特征的重要性系数, 有效地对变量之间的相关性进行分析。RF 算法的基本原理是通过随机重抽样产生多个训练集, 在每个训练集中通过反复二分数据构建决策树, 再把各个决策树构建成一个集成模型。RF 选取特征变量的步骤如下:

1) 设置决策树的个数为 n , 通过 bootstrap 方法从数据集中抽取 n 个子样本数据集, 未被抽取的样本集记为袋外数据, 用于训练以构建决策树。

2) 把每个子样本集构建一个决策树, 以方差最小作为分支准则来选取最优特征作为决策树节点的划分。

$$I = \min \frac{\sum_{s=1}^n (X_s - \bar{X}_s)^2}{n} \quad (8)$$

式中, I 是最优特征变量, n 是样本数, X_s 为变量 s 的样本值, \bar{X}_s 是变量 s 的样本平均值。RF 算法通过均方误差作为评价指标来判断输入特征的重要度, 计算均方误差如式 (9) 所示:

$$MSE = \frac{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}{n} \quad (9)$$

3) RF 采用袋外数据对 n 个决策树进行测试, 得到均方误差 $[MSE_1, MSE_2, \dots, MSE_k]$ 。通过式 (10) 计算特征的重要度。

$$V_{im} = \frac{\sum_{j=1}^k (MSE_j - MSE_{kj})}{k \times S_E} \quad (10)$$

式中, V_{im} 表示特征的重要度, k 是决策树的个数, S_E 是决策树标准误差。利用 RF 算法可以得到各个特征对负荷的

影响系数, 但无法确定预测模型的最佳输入特征个数, 因此本文采用 RF 结合递归特征消除法 (RFE) 来确定最佳特征数量。RFE 主要原理通过反复建立模型, 对各个特征的得分进行排序, 选择的得分最高的特征, 最终构建一个新的特征子集, 遍历所有特征后停止, 最终得到最佳特征数量。

1.3 门控循环单元

GRU 由“更新门”和“重置门”组成, “更新门”决定有多少以前的状态应该保留, 有多少新的输入应该添加, 而“重置门”决定有多少以前的状态应该被忽略。通过简化 LSTM 的结构, GRU 显示出更高的计算效率, 同时取得了相当的性能。标准的 GRU 神经网络结构如图 1 所示。

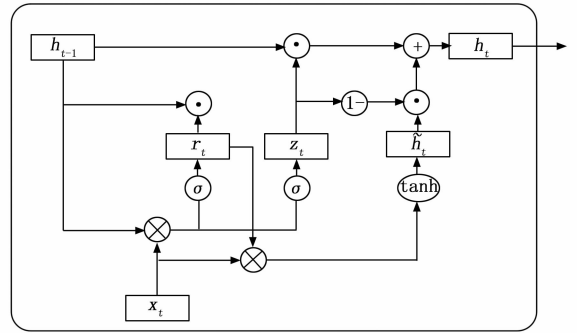


图 1 标准 GRU 结构

GRU 中的重置门实现了对输入以及先前状态进行选择遗忘和更新的能力, 输入变量 x_t 与前一时刻的隐状态变量 h_{t-1} 经过 Sigmoid 非线性变换后输入到重置门中, 如式 (11) 所示:

$$r_t = \sigma(x_t W_r + h_{t-1} U_h + b_r) \quad (11)$$

式中, r_t 作为重置门, σ 为 Sigmoid 激活函数, x_t 为 t 时刻的输入信息, W_r 表示当前重置门下输入信息权重参数, h_{t-1} 为 $t-1$ 时刻的隐藏层状态, U_h 为当前隐藏层状态下重置门的权重参数, b_r 是偏置参数。

更新门是控制候选状态 h_t 是否依赖上一时刻的状态 h_{t-1} , 过滤部分前一时刻隐藏状态的信息, 保留有价值的信息。

$$z_t = \sigma(x_t W_z + h_{t-1} U_z + b_z) \quad (12)$$

式中, z_t 作为更新门, W_z 为更新门下输入信息权重参数, U_z 为当前隐藏层状态下更新门的权重参数, b_z 是偏置参数。

当前时刻的候选状态 \tilde{h}_t , 由上一时刻的隐藏状态 h_{t-1} 与重置门 r_t 进行矩阵相乘得到, 并与当前时刻输入 x_t 经过 tanh 激活函数转化而来。

$$\tilde{h}_t = \tanh(x_t W_h + (r_t \odot h_{t-1}) U_h + b_h) \quad (13)$$

式中, \tanh 为激活函数, \odot 表示向量中按元素点乘。 U_h 是权重参数, b_h 偏置参数。

细胞单元当前时刻的隐藏状态 h_t , 由上一时刻的隐藏状态 h_{t-1} 和当前时刻的候选状态 \tilde{h}_t , 分别经过更新门 z_t 作用后得到。综上, GRU 的状态更新公式为:

$$h_i = z_i \odot h_{i-1} + (1 - z_i) \odot \tilde{h}_i \quad (14)$$

在建筑冷负荷预测过程中，GRU 神经网络的关键优势在于其能够有效地利用前一时刻的历史冷负荷信息来处理序列数据，以及借助该信息影响下一时刻的冷负荷输出，正因如此，本文选择采用 GRU 神经网络。

1.4 秃鹰搜索算法

秃鹰搜索 (BES) 算法由马来西亚学者 Alsatter^[26] 提出，这是一种新颖的启发式优化算法，模仿秃鹰在寻找猎物时的狩猎行为。BES 算法相对于其他群智能优化算法的优点是搜索能力强，收敛速度快。该算法可分为 3 个阶段：在第一阶段 (选择阶段)，秃鹰种群选择猎物数量最多的空间；在第二阶段 (搜索阶段)，秃鹰种群在选定的空间内搜索猎物；在第三阶段 (俯冲阶段)，秃鹰从第二阶段确定的最佳位置俯冲捕获猎物。

1.4.1 选择阶段

秃鹰种群搜索空间位置更新公式如下：

$$P_{i,new} = P_{best} + \alpha \times r \times (P_{mean} - P_i) \quad (15)$$

式中， α 是控制秃鹰位置变化的参数，取值在 1.5~2 之间， r 作为随机数，取值在 0~1 之间。 $P_{i,new}$ 表示第 i 个秃鹰更新的位置， P_{best} 表示秃鹰种群选择的最优位置， P_{mean} 是当前秃鹰种群的平均位置， P_i 表示种群中第 i 个秃鹰个体的位置。

1.4.2 搜索阶段

在搜索阶段中，秃鹰种群在确定的搜索空间中搜寻猎物，并在空间中以螺旋状飞行，确定俯冲捕食猎物的最佳位置，秃鹰种群位置更新公式如下：

$$P_{i,new} = P_i + x(i) \times (P_i - P_{mean}) + y(i) \times (P_i - P_{i+1}) \quad (16)$$

$$x(i) = \frac{xr(i)}{\max(|xr|)}, y(i) = \frac{yr(i)}{\max(|yr|)} \quad (17)$$

$$\begin{cases} xr(i) = r(i) \times \sin(\theta(i)) \\ yr(i) = r(i) \times \cos(\theta(i)) \end{cases} \quad (18)$$

$$\begin{cases} \theta(i) = a \times \pi \times rand \\ r(i) = \theta(i) + R \times rand \end{cases} \quad (19)$$

式中， a 为控制螺旋飞行角度参数，取值范围为 5~10； R 为控制螺旋飞行圈数参数，取值范围为 0.5~2； $\theta(i)$ 与 $r(i)$ 分别为螺旋运动方程的极角与极径； $xr(i)$ 和 $yr(i)$ 为确定秃鹰的极坐标位置，取值范围均为 -1~1， P_{i+1} 表示第 $i+1$ 只秃鹰的当前位置。

1.4.3 俯冲阶段

在俯冲阶段，秃鹰在搜索空间中的最佳位置向目标猎物俯冲，秃鹰种群中其他个体也向最佳位置移动并对猎物展开攻击，种群位置更新公式如下：

$$P_{i,new} = rand \times P_{best} + x1(i) \times (P_i - c1 \times P_{mean}) + y1(i) \times (P_i - c2 \times P_{best}) \quad (20)$$

$$x1(i) = \frac{xr(i)}{\max(|xr|)}, y1(i) = \frac{yr(i)}{\max(|yr|)} \quad (21)$$

$$\begin{cases} xr(i) = r(i) \times \sinh(\theta(i)) \\ yr(i) = r(i) \times \cosh(\theta(i)) \end{cases} \quad (22)$$

$$\begin{cases} \theta(i) = a \times \pi \times rand \\ r(i) = \theta(i) \end{cases} \quad (23)$$

式中， $c1$ 和 $c2$ 是秃鹰向最佳点和中心点的移动强度，取值范围为 [1, 2]。


2 模型的改进与框架

2.1 改进秃鹰搜索算法


相较于其他智能优化算法，秃鹰搜索算法在收敛速度和搜索性能好，但算法本身仍存在容易陷入局部最优和收敛精度低的问题，在求解过程中还有许多改进空间。因此本文提出 3 个改进策略对原始的秃鹰搜索算法进行改进。

2.1.1 Sobol 序列初始化种群

群智能算法的初始解在解空间中的分布影响算法的收敛速度和优化性能。原始 BES 算法采用随机初始化种群的方式，导致初始解分布相对不均匀，进而影响算法的性能。为解决这一问题，本文采用 Sobol 序列来初始化秃鹰搜索算法的种群。Sobol 序列是一种低差异的随机序列，其特点在于每个维度都使用底数为 2 的根基反转矩阵，使得在每个维度上生成均匀且不重复的初始候选解。为验证 Sobol 序列与随机分布在解空间中的分布差异，本文生成一个规模为 100 的种群，并绘制它们在二维空间的随机数分布图。由图 2 对比可知，通过 Sobol 序列生成的种群分布更均匀且覆盖解空间更全面。



(a) 随机生成个体散点图



(b) Sobol 序列生成个体散点图

图 2 随机法与 Sobol 序列生成个体分布图

2.1.2 非线性控制因子

在秃鹰搜索算法的选择搜索空间阶段，寻优性能由控制因子 α 决定，其值随机在 [1.5, 2] 内选取，若选取后的值过小，导致秃鹰种群所在位置聚集，收敛速度加快，但

全局搜索能力下降;若选取后的值过大,导致秃鹰种群位置分散,搜索范围扩大,提高全局搜索能力,但局部搜索能力下降。因此,为了最大化地发挥秃鹰搜索算法的寻优能力,本文提出一种非线性控制因子 CL ,用于搜索空间范围中,它可以被定义为:

$$CL = \alpha \times \left(\frac{T_{\max} - t}{T_{\max} + t} + 1 \right) \quad (24)$$

式中, T_{\max} 作为最大迭代次数, t 为当前迭代次数。迭代初期全局搜索时,控制因子 CL 较大,非线性变化速率快,这使得种群不断探索未知区域,保持较高的全局搜索能力,从而防止算法过早收敛。在迭代后期 CL 较小,非线性变化速率慢,保持较高的局部搜索能力,提高算法的收敛速度。此时秃鹰种群在第一阶段的位置更新公式,如下式所示:

$$P_{i,\text{new}} = P_{\text{best}} + CL \times r \times (P_{\text{mean}} - P_i) \quad (25)$$

2.1.3 自适应 t 分布

t 分布又被称为学生分布,含有参数自由度 m , t 分布的曲线形态与自由度 m 相关,它的概率密度函数为:

$$P_i(x) = \frac{\Gamma\left(\frac{m+1}{2}\right)}{\sqrt{m\pi} \times \Gamma\left(\frac{m}{2}\right)} \times \left(1 + \frac{x^2}{m}\right)^{-(m+1)/2} \quad (26)$$

当 t 分布的自由度 m 为 1 时,此时 t 分布为柯西分布。当 t 分布的自由度 m 为无穷大时,此时 t 分布为高斯分布,柯西分布和高斯分布都是 t 分布的两种特殊形式。为了解决秃鹰搜索算法在迭代后期陷入局部最优的问题,本文采用 t 分布对秃鹰个体位置进行扰动更新。此时秃鹰位置更新公式为:

$$P_{i,\text{new}} = P_i + P_i \times t(\text{iter}) \quad (27)$$

式中, P_i 为秃鹰个体的位置, $P_{i,\text{new}}$ 为 t 分布扰动后的新位置, $t(\text{iter})$ 作为自由度为 iter 的 t 分布算子。在算法迭代早期 iter 较小, t 分布接近柯西分布,通过 $t(\text{iter})$ 对秃鹰个体 P_i 进行扰动,增强算法的全局搜索能力。在算法迭代后期 iter 较大, t 分布接近高斯分布,此时 $t(\text{iter})$ 对秃鹰个体 P_i 扰动减弱,增强算法的局部搜索能力,加快算法收敛速度。在算法迭代的中期, t 分布是由柯西分布逐渐转向高斯分布,它具有两种分布的优点,能够平衡算法的全局和局部搜索

能力。

2.2 IBES 性能验证

本文的实验环境在 12th Gen Intel (R) Core (TM) i5-12500H, Matlab2022b 中验证 IBES 算法的性能。选取 4 个经典标准测试函数进行测试,如表 1 所示,其中函数 Sphere 和 Rosenbrock 为单峰函数,用于检验算法的收敛速度和局部快速求解能力的准确性, Ackley 和 Penalized 为多峰函数,用于测试算法的全局搜索能力和跳出局部最优解的能力,测试函数最优解为 0。本文用上述的 4 个标准测试函数对粒子群算法 (PSO), 鲸鱼优化算法 (WOA), 灰狼优化算法 (GWO), BES, IBES 算法进行测试,种群规模均为 30,最大迭代次数均为 500,测试函数维度为 30。在同一实验环境下,分别对每个测试函数独立运行 30 次,采用结果的平均值,标准差和最小值作为算法性能评价指标。

通过分析表 2 中的数据,可以得出本文优化算法在 4 个标准测试函数中运行的结论。在 Sphere 函数中,相较于另外 3 种算法, IBES 和 BES 算法都能直接探索到最小值,显示出这两种算法在该单峰函数中的出色性能。进一步考察 Rosenbrock 函数,该函数是测试优化算法性能的非凸函数,具有多个局部最小值和复杂的鞍点结构,使算法难以收敛到最小值。然而 IBES 在 Rosenbrock 函数中求解的最小值远低于其余算法,结果表明 IBES 算法在处理非凸优化问题时具有较高的效率和准确性,能够在复杂的函数结构中实现更为精确的全局最小值搜索。在 Ackley 和 Penalized 这两个多峰函数中, IBES 算法相对于其他算法展现出更高的寻优性能,同时也说明 IBES 算法在处理具有多个局部极小值的复杂多峰函数中的优越表现。这些结果说明 IBES 算法在单峰和多峰函数的求解能力上都具有优势。此外,结合图 3 可以进一步看出,在 4 个测试函数的迭代曲线中, IBES 算法的迭代速度更快,搜索最优解的能力更强,而且在求解适应度值的过程中,其稳定性也优于其他 4 种算法。因此, IBES 算法具有良好的稳定性和较快的收敛速度,能够适用于 GRU 超参数优化。由此可见,本文提出的 IBES 算法具有更好的搜索能力和更好的稳定性,具有良好的应用价值。

表 1 测试函数

测试函数	公式	范围
Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	-100~100
Rosenbrock	$F_2(x) = \sum_{i=1}^n [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	-30~30
Ackley	$F_3(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right] + 20 + e$	-32~32
Penalized	$F_4(x) = \frac{\pi}{n} (10 \sin^2(\pi y_1) + \sum_{i=1}^n (y_i - 1)^2 [1 + \sin^2(\pi y_{i+1})]) + \sum_{i=1}^n u(x_i, 10, 100, 4)$	-50~50

表 2 优化算法在 4 个标准测试函数运行结果

测试函数	指标	PSO	GWO	WOA	BES	IBES
Sphere	平均值	446	406	356	0.257	0.057 7
	标准差	3 600	3 600	294	1.29	1.09
	最小值	8.16×10^{-3}	3.34×10^{-4}	1.45×10^{-4}	0	0
Rosenbrock	平均值	6.81×10^5	1.05×10^6	1.01×10^5	1.16	0.090 6
	标准差	9.13×10^6	1.12×10^7	1.19×10^6	16.7	1.50
	最小值	0.928	26.2	25.4	4.43×10^{-4}	2.94×10^{-6}
Ackley	平均值	2.04	0.584	1.19×10^{-4}	0.075 6	0.030 8
	标准差	3.08	2.75	1.82×10^{-3}	0.016 6	5.59×10^{-3}
	最小值	8.77×10^{-3}	2.89×10^{-14}	4.53×10^{-12}	5.43×10^{-16}	4.44×10^{-16}
Penalized	平均值	1.31×10^6	4.27×10^6	3.27×10^6	8.16×10^{-4}	7.14×10^{-5}
	标准差	3.73×10^7	3.73×10^7	3.13×10^7	0.016 1	6.85×10^{-4}
	最小值	2.69	0.028 7	5.73×10^{-3}	3.12×10^{-8}	1.54×10^{-13}

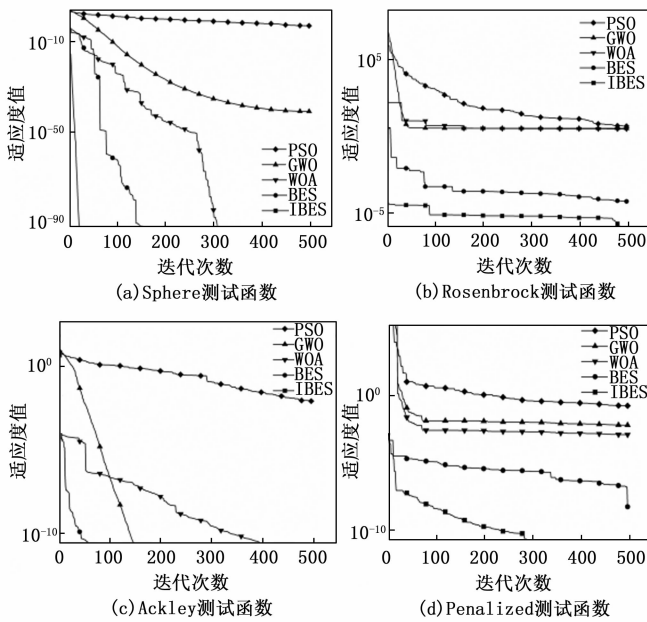


图 3 测试函数迭代曲线图

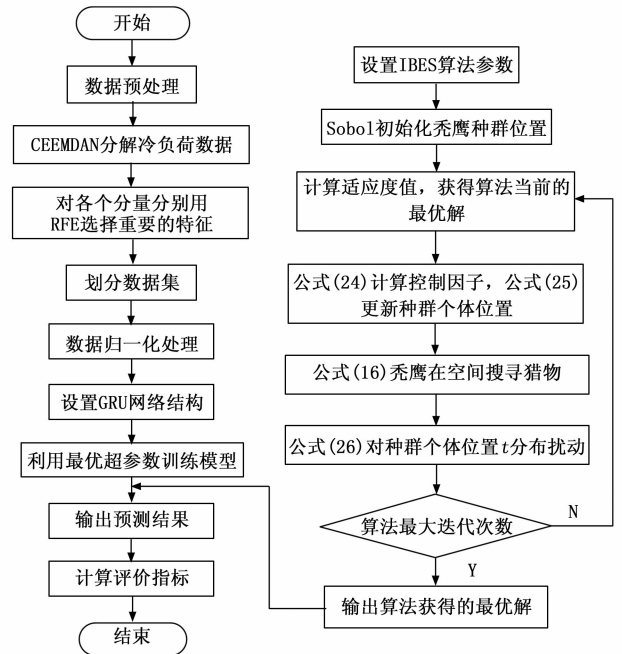


图 4 CEEMDAN-IBES-GRU 模型流程图

2.3 提出的混合预测模型

在优化 GRU 时，采用 IBES 算法将 GRU 的平均绝对误差 (MAE) 作为 IBES 的适应度函数，如式 (28) 所示。在此过程中，秃鹰个体的位置被用作 GRU 中待优化的超参数，包括隐藏层神经元个数、初始学习率和 L2 正则化系数。选择这 3 个超参数的原因是：隐藏层神经元个数对神经网络的学习能力具有决定性作用；初始学习率影响网络的收敛能力；而 L2 正则化系数则用于防止过拟合现象的发生：

$$fitness = \frac{\sum_{i=1}^n |\hat{y}_i - y_i|}{n} \quad (28)$$

式中， \hat{y}_i 为 GRU 测试集的预测值， y_i 为测试集的真实值， n 为测试集样本个数。本文提出的 CEEMDAN-IBES-GRU 模型的模型流程如图 4 所示，具体实施步骤如下：

- 1) 对原始数据进行预处理，剔除数据中的异常值；
- 2) 采用 CEEMDAN 算法对原始冷负荷数据分解，利用 RFE 算法对影响冷负荷特征进行筛选，选择与负荷显著相关的特征作为模型输入，获得最终数据集，将数据集划分为训练集和测试集，并归一化处理；
- 3) 设置 GRU 网络结构，秃鹰搜索算法的种群数量和最大迭代次数；
- 4) 采用 Sobol 序列优化秃鹰种群初始位置。把平均绝对误差 (MAE) 值作为 IBES 的适应度函数，计算适应度值，获得算法当前的最优解；
- 5) 在秃鹰选择搜索阶段，使用式 (25) 进行位置更新，在秃鹰搜索空间猎物阶段，利用式 (16) 进行种群位置更新，在俯冲捕获猎物阶段，利用式 (27) 进行 t 分布扰动变异更新种群位置。

6) 继续计算种群个体适应度值, 保存最优个体和全局位置;

7) 如果适应度值小于模型的阈值, 则此时输出最优超参数并将其赋值给 GRU 模型进行训练; 否则, 跳到 4) 继续寻优, 直到满足条件为止;

8) 输出模型的预测结果。

3 案例研究

3.1 实验数据来源

本文以陕西省西安市一栋商业建筑为研究对象, 该商业建筑共有 8 层, 建筑面积 15.5 万 m²。数据记录日期从 2022 年 5 月 1 日到 8 月 31 日, 总共 122 天。为了进行预测模型的训练和测试, 本文选取该建筑的空调机组运行的冷负荷数据为案例。冷负荷数据来源于该建筑的能耗监测管理平台, 而室外气象数据来源于该建筑所安装的环境监测传感器, 数据采样频率均为 1 小时。采用 CEEMDAN 算法将冷负荷数据分解为 IMF 9 个分量 (IMF1, IMF2, ..., IMF9) 和一个残差分量, 分解结果如图 5 所示, 将各 IMF 分量与原始数据中的特征构成新的数据集。由于影响建筑冷负荷的特征具有不同的量纲单位, 需要对原始冷负荷数据和气象数据进行归一化处理, 归一化公式如式 (29) 所示:

$$Z^* = \frac{z - z_{\text{mean}}}{z_{\text{std}}} \quad (29)$$

式中, Z^* 为原始数据归一化后数据, z_{mean} 为原始数据的均值, z_{std} 为原始数据的标准差。

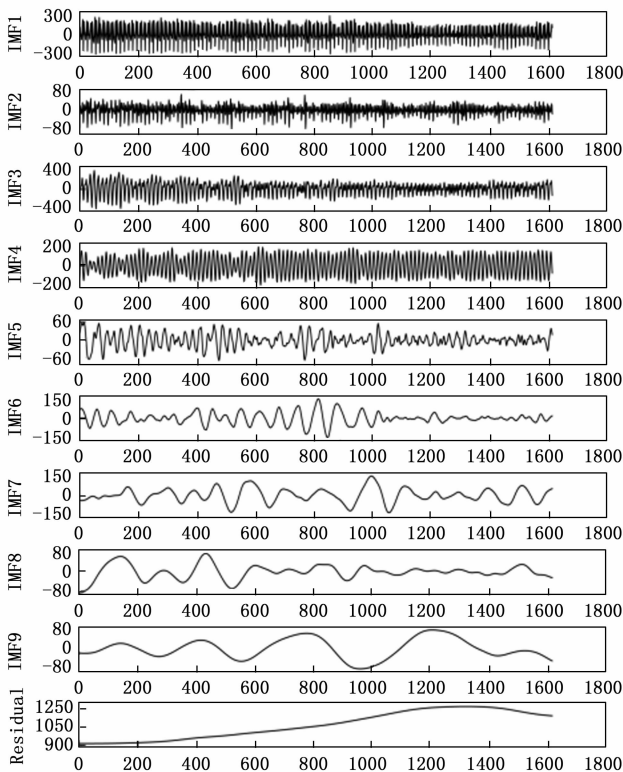


图 5 建筑冷负荷数据分解结果

3.2 输入特征选择

本文研究目的是预测未来一小时的冷负荷。同时考虑到冷负荷的滞后性, 将历时 3 小时的冷负荷和气象变量共 18 个特征作为输入, 如表 3 所示。然后, 将这些特征输入到 RF 算法中进行特征选择。虽然通过 RF 算法可以得到特征的影响系数, 但无法确定最佳输入特征的数量。因此本文将 RF 计算后的特征输入 RFE 中, 通过排序构成一个新的特征集合。这一方法的优势在于充分考虑冷负荷预测的复杂性, 不仅考虑历史数据的影响, 还通过结合 RF 和 RFE 算法, 进一步提炼出最为关键和具有显著性的特征, 以提高模型的性能和预测准确性。

表 3 输入的特征

符号	特征意义	单位
Lag1, Lag2, Lag3	前 1~3 时刻冷负荷值	kW
SR1, SR2, SR3	前 1~3 时刻太阳辐射量	W/m ²
Temp1, Temp2, Temp3	前 1~3 时刻室外温度	°C
RH1, RH2, RH3	前 1~3 时刻室外湿度	%
WS1, WS2, WS3	前 1~3 时刻室外风速	m/s
WD1, WD2, WD3	前 1~3 时刻室外风向	deg

IMF1 分量的特征选择采用 RF 算法, 计算结果如图 6 所示, 并结合 RFE 方法得出了最佳特征数量, 如图 7 所示。在 RFE 的过程中, 从潜在影响负荷的 18 个特征中, 选出 8 个最为关键的特征, 包括前 1~2 小时的室外温度、前 1~3 小时的太阳辐射量、前 1~2 小时的冷负荷值以及前 1 小时的室外相对湿度。这 8 个特征随后被纳入模型的输入参数中, 通过同样的算法, 对其他 IMF 分量逐一进行特征选择, 而具体的结果则展示在表 4 中。在经过特征选择过程后, 不同频率的 IMF 分量选择不同的特征, 进一步证明了不同频率数据分量具有各自的特征。这也验证了对不同数据分量进行特征选择的必要性, 确保在建模和分析过程中能够获得更准确的结果, 因为特定频率范围内的特征对于模型性能的影响是显著的, 而特征选择有助于有效地捕捉这些重要特征, 提高模型的预测准确性。




图 6 特征的影响系数




图 7 RFE 交叉验证得分

表 4 不同 IMF 分量的特征选择结果

IMF 分量	所选特征
IMF1	Temp1, Temp2, Lag1, Lag2, SR1, SR2, SR3, RH1
IMF2	Temp1, Lag1, SR1, SR2, RH1
IMF3	Temp1, Lag1, SR1, RH1
IMF4	Temp1, RH1, Lag1, SR1
IMF5	Temp1, Lag1, SR1, SR2
IMF6	Temp1, Lag1, SR1
IMF7	Temp1, Lag1, SR1
IMF8	Temp1, Lag1, SR1, Temp2, SR2
IMF9	Temp1, Lag1, SR1, SR2, RH1
Residual	Temp1, Lag1, SR1, RH1

3.3 预测结果分析

考虑到该商业建筑的工作特点，每天 9:00—21:00 为营业时间。因此，本文实验使用 5 月 1 日至 8 月 23 日上午 8:00 至晚上 21:00 的数据作为训练数据，使用 8 月 24 日至 31 日的数据作为测试数据。同时，为了验证模型的预测效果，选取评价预测模型性能的 3 个重要指标，分别为均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 和平均绝对误差 (MAE) 相应的计算公式如下：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (30)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (31)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n | \hat{y}_i - y_i | \quad (32)$$

式中， n 作为样本总数， \hat{y}_i 为测试集中的预测值， y_i 为测试集中的真实值。

为了评估模型的改进部分对预测精度的影响，将改进前和改进后的模型进行比较分析，预测结果如表 5 所示。在这 4 个预测模型中，CEEMDAN-IBES-GRU 模型预测精度最高，其 RMSE，MAPE 和 MAE 分别为 10.8，0.85% 和 7.27，与未使用 CEEMDAN 算法的 IBES-GRU 相比，本

文模型 RMSE 减少 18.4，MAPE 减少 1.52%，MAE 减少 15.38。这是因为本文模型采用 CEEMDAN 算法将冷负荷数据为不同频率的分量，然后对不同频率分量挖掘特征规律针对性地建立模型，可以有效提高模型的预测精度。其次，本文提出的模型相较于未采用 BES 算法的 CEEMDAN-GRU 模型，在 RMSE 方面减少 10.35，MAPE 减少 0.93%，MAE 减少 9.92，这些结果表明本文提出的 IBES 算法在优化 GRU 的超参数中发挥关键作用，通过自动搜索最优的隐藏层神经元个数、初始学习率和 L2 正则化系数，IBES 算法能够有效地优化 GRU 模型的超参数，使其更加适应本文的数据集，从而提高模型的预测能力。为了更清楚地呈现对比结果，图 8 展示了这 4 种模型的预测折线图。与其他 3 种预测模型相比，CEEMDAN-IBES-GRU 得到的建筑冷负荷预测值与实际值相差最小，拟合效果更好，具有最好的预测效果。

表 5 4 种预测模型结果对比

预测模型	RMSE	MAPE/%	MAE
CEEMDAN-IBES-GRU	10.8	0.85	7.27
CEEMDAN-GRU	21.15	1.78	17.19
IBES-GRU	29.2	2.37	22.65
GRU	45.07	3.57	34.52




图 8 4 种模型预测结果对比

为了深入验证本文提出的预测模型的准确性，将本文模型与 CEEMDAN-IBES-LSTM、IBES-LSTM、BES-GRU、LSTM、CNN、RBF 和 BP 多个模型进行对比分析，各模型的预测结果如表 6 所示。数据表明 CEEMDAN-IBES-GRU 比其他模型的误差都小，因此本文提出的组合模型性能上相比其他模型有所提升。CEEMDAN-IBES-

GRU 相较于 CEEMDAN-IBES-LSTM, 在 *RMSE*、*MAPE* 和 *MAE* 方面分别减少 6.61、0.43% 和 4.79。这表明 GRU 模型比 LSTM 模型更适用于作为本文的基础模型来建立商业建筑冷负荷预测模型。另外本文提出的 IBES-GRU 相对于 BES-GRU, 在 *RMSE*、*MAPE* 和 *MAE* 方面分别减少 4.01, 1.11%, 9.88。这些结果表明, 引入 Sobol 序列初始化种群、采用非线性控制因子和自适应 t 分布这 3 种改进策略, 能有效提升 BES 算法对 GRU 参数寻优能力。最后进一步探讨 IBES 算法的通用性, IBES-LSTM 相对于原始 LSTM 模型, 其 *RMSE*、*MAPE* 和 *MAE* 分别减少 17.27、1.31% 和 11.56。这表明本文提出的 IBES 算法, 不仅在 GRU 超参数优化中表现卓越, 同样在 LSTM 超参数优化中展现出显著的优越性。

表 6 不同预测模型对比结果

预测模型	<i>RMSE</i>	<i>MAPE</i> /%	<i>MAE</i>
CEEMDAN-IBES-GRU	10.8	0.85	7.27
CEEMDAN-IBES-LSTM	17.41	1.28	12.06
IBES-GRU	29.2	2.37	22.65
IBES-LSTM	30.6	2.56	25.87
BES-GRU	33.21	3.48	32.53
GRU	45.07	3.57	34.52
LSTM	47.87	3.87	37.44
CNN	49.99	4.13	42.22
RBF	55.80	4.45	45.13
BP	63.94	4.92	52.08

3.4 CEEMDAN 分解性能验证分析

为了验证 CEEMDAN 分解算法对于冷负荷预测的有效性, 本文采用不同神经网络模型对建筑冷负荷进行预测。在实验过程中, 确保特征选择方法的一致性, 通过对比未经过 CEEMDAN 分解和经过 CEEMDAN 分解的神经网络模型, 使用 *RMSE*、*MAPE* 和 *MAE* 作为评价指标, 实验结果如表 7 所示。在所有的神经网络中, 使用 CEEMDAN 分解的情况下, *RMSE*、*MAPE* 和 *MAE* 都相对较低, 这明确指出了 CEEMDAN 分解在提高模型性能方面发挥了积极作用。其次, 在不同情况下, GRU 模型在 CEEMDAN 分解和未分解的情况下都表现出最低的 *RMSE*、*MAPE* 和 *MAE*, 这表明 GRU 模型具有较好的稳定性和准确性。相比之下, BP 神经网络表现最差, 由于其对于非线性数据的拟合能力较弱。这表明在本文的冷负荷预测任务中, GRU 模型相对于其他模型更为有效。最后, CEEMDAN 算法的有效性体现在它将冷负荷分解成多个不同频率的分量, 为每个分量建立模型并挖掘特征规律。特别是在处理具有非线性和非平稳性特点的建筑冷负荷数据时, CEEMDAN 分解有助于提高模型的预测准确性。通过使用 CEEMDAN 分解方法, 可以更好地捕捉和利用时间序列数据中的不同频率变化信息, 从而提高 GRU 模型的预测性能。

表 7 不同神经网络分解结果

预测模型	是否 CEEMDAN 分解	<i>RMSE</i>	<i>MAPE</i> /%	<i>MAE</i>
GRU	是	21.15	1.78	17.19
	否	45.07	3.57	34.52
LSTM	是	29.86	2.45	24.34
	否	47.87	3.87	37.44
CNN	是	30.49	2.26	22.46
	否	49.99	4.13	42.22
RBF	是	32.83	2.74	28.64
	否	55.08	4.45	45.13
BP	是	39.51	2.59	24.81
	否	63.94	4.92	52.08

4 结束语

准确预测大型公共建筑的冷负荷是一项具有挑战性的任务。根据预测的冷负荷需求制定空调系统运行计划, 可以有效防止能源浪费。本文针对以往研究的不足提出了一种新的用于大型公共建筑冷负荷预测的混合预测模型 CEEMDAN-IBES-GRU。与传统预测模型相比, 该模型可以根据不同频率分量, 针对性挖掘数据信息, 提高模型预测精度。同时, 针对 IBES 的缺陷问题, 采用 Sobol 序列、非线性控制因子和自适应 t 分布 3 种策略来改进以更加高效地为 GRU 找到更合适的超参数。最后利用陕西省西安市某大型公共建筑实际运行数据进行验证, 并和其常用性能较好的模型进行对比分析。可以得出以下结论:

1) CEEMDAN-IBES-GRU 的误差与 IBES-GRU 相比, *RMSE* 减少 18.4, *MAPE* 减少 1.52%, *MAE* 减少 15.38, 说明 CEEMDAN 可以提高预测模型准确性, 根据不同周期分量, 针对性挖掘数据信息是一种更细致精确的数据处理方法。

2) 通过 4 个标准测试函数对 IBES 进行验证, IBES 算法在每个测试函数的最小值, 平均值和标准差均优于 PSO, GWO, WOA, BES 算法, 说明对 BES 的 3 个改进措施有效, 改进的 IBES 算法找到最优解的速度更快, 收敛曲线更平稳。

3) CEEMDAN-IBES-GRU 的误差比 GRU, *RMSE*、*MAPE* 和 *MAE* 明显降低, 说明本文模型的改进有效, 比基准模型 GRU 有较大的性能提升。另外 CEEMDAN-IBES-GRU 比 CEEMDAN-IBES-LSTM、IBES-LSTM、LSTM、CNN、RBF 和 BP 等主流模型预测精度更高, 更适合对大型公共建筑冷负荷进行精确预测。

本文的研究存在一些不足之处, 未来的研究可以集中在以下几个方面: 首先, 寻找更多更快地对神经网络超参数优化算法, 进一步降低混合预测模型的复杂性。其次, 引入更多的特征变量, 进一步提高建筑冷负荷预测的准确性及其在实际工程中的应用。最后, 把预测模型应用在不同的

建筑类型, 如居住建筑, 办公建筑, 教育建筑等, 并将进一步提高预测模型的学习和泛化能力。通过这些改进措施, 我们可以进一步完善建筑冷预测模型, 并为实际应用提供更准确可靠的结果。

参考文献:

- [1] LIN X, TIAN Z, LU Y, et al. Short-term forecast model of cooling load using load component disaggregation [J]. *Applied Thermal Engineering*, 2019, 157: 113630.
- [2] SHI H, CHEN Q. Building energy management decision-making in the real world: a comparative study of HVAC cooling strategies [J]. *Journal of Building Engineering*, 2021, 33: 101869.
- [3] YANG J, WU J, XIAN T, et al. Research on energy-saving optimization of commercial central air-conditioning based on data mining algorithm [J]. *Energy and Buildings*, 2022, 272: 112326.
- [4] FAN C, XIAO F, ZHAO Y. A short-term building cooling load prediction method using deep learning algorithms [J]. *Applied Energy*, 2017, 195: 222 - 233.
- [5] ATALAY SD, CALIS G, KUS G, et al. Performance analyses of statistical approaches for modeling electricity consumption of a commercial building in France [J]. *Energy and Buildings*, 2019, 195: 82 - 92.
- [6] FATHI S, SRINIVASAN R, FENNER A, et al. Machine learning applications in urban building energy performance forecasting: a systematic review [J]. *Renewable and Sustainable Energy Reviews*, 2020, 133: 110287.
- [7] RAHMAN A, SRIKUMAR V, SMITH AD. Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks [J]. *Applied Energy*, 2018, 212: 372 - 385.
- [8] ZHOU Y, LIU Y, WANG D, et al. Comparison of machine-learning models for predicting short-term building heating load using operational parameters [J]. *Energy and Buildings*, 2021, 253: 111505.
- [9] 孟宋萍, 彭伟, 田晨璐. 基于门控循环单元的非均衡数据驱动异常用电检测方法 [J]. *计算机测量与控制*, 2023, 31 (10): 54 - 60.
- [10] OZDEMIR A C, BULUS K, ZOR K. Medium-to long-term nickel price forecasting using LSTM and GRU networks [J]. *Resources Policy*, 2022, 78: 102906.
- [11] FAN C, WANG J, GANG W, et al. Assessment of deep recurrent neural network-based strategies for short-term building energy predictions [J]. *Applied Energy*, 2019, 236: 700 - 710.
- [12] WEN L, ZHOU K, YANG S. Load demand forecasting of residential buildings using a deep learning model [J]. *Electric Power Systems Research*, 2020, 179: 106073.
- [13] DONG F, WANG J, XIE K, et al. An interval prediction method for quantifying the uncertainties of cooling load based on time classification [J]. *Journal of Building Engineering*, 2022, 56: 104739.
- [14] LI J, ZHANG Z, WANG X, et al. Intelligent decision-making model in preventive maintenance of asphalt pavement based on PSO-GRU neural network [J]. *Advanced Engineering Informatics*, 2022, 51: 101525.
- [15] ZHANG C, JI C, HUA L, et al. Evolutionary quantile regression gated recurrent unit network based on variational mode decomposition, improved whale optimization algorithm for probabilistic short-term wind speed prediction [J]. *Renewable Energy*, 2022, 197: 668 - 682.
- [16] KILINC H C, YURTSEVER A. Short-term streamflow forecasting using hybrid deep learning model based on grey wolf algorithm for hydrological time series [J]. *Sustainability*, 2022, 14 (6): 3352.
- [17] MA H, ZHANG C, PENG T, et al. An integrated framework of gated recurrent unit based on improved sine cosine algorithm for photovoltaic power forecasting [J]. *Energy*, 2022, 256: 124650.
- [18] JIA P, ZHANG H, LIU X, et al. Short-term photovoltaic power forecasting based on VMD and ISSA-GRU [J]. *IEEE Access*, 2021, 9: 105939 - 105950.
- [19] GAO Y, HANG Y, YANG M. A cooling load prediction method using improved CEEMDAN and Markov Chains correction [J]. *Journal of Building Engineering*, 2021, 42: 103041.
- [20] JIAO Y, TAN Z, ZHANG D, et al. Short-term building energy consumption prediction strategy based on modal decomposition and reconstruction algorithm [J]. *Energy and Buildings*, 2023, 290: 113074.
- [21] ZHANG L, ALAHMAD M, WEN J. Comparison of time-frequency-analysis techniques applied in building energy data noise cancellation for building load forecasting: A real-building case study [J]. *Energy and Buildings*, 2021, 231: 110592.
- [22] LI K, HUANG W, HU G, et al. Ultra-short term power load forecasting based on CEEMDAN-SE and LSTM neural network [J]. *Energy and Buildings*, 2023, 279: 112666.
- [23] 石志炜, 张丽萍. 基于改进小波包阈值降噪的滚动轴承故障分析 [J]. *计算机测量与控制*, 2019, 27 (5): 58 - 63.
- [24] KARIJADI I, CHOU S Y. A hybrid RF-LSTM based on CEEMDAN for improving the accuracy of building energy consumption prediction [J]. *Energy and Buildings*, 2022, 259: 111908.
- [25] BREIMAN L. Random forests [J]. *Machine Learning*, 2001, 45: 5 - 32.
- [26] ALSATTAR H A, ZAIDAN A A, ZAIDAN B B. Novel meta-heuristic bald eagle search optimisation algorithm [J]. *Artificial Intelligence Review*, 2020, 53: 2237 - 2264.