

改进鲸鱼算法构建混合模型的建筑能耗预测

王茹, 宋爽, 贺佳

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

摘要: 建筑能耗数据具有非平稳和非线性特征, 单一预测模型很难对其进行精准预测, 提出一种用于建筑能耗短期预测的新型混合模型; 利用互补集合经验模态分解方法 (CEEMD) 将波动性较大的能耗数据分解为一组本征模态函数和一个残差序列; 基于反向学习、差分进化算法并引入控制参数 λ 对鲸鱼优化算法 (WOA) 进行改进, 有效解决算法早熟收敛与陷入局部最优等的问题, 提出改进算法 UWOA (upgraded whale optimization algorithm); 利用 UWOA 优化 Elman 神经网络的权值与阈值, 优化后的 Elman 神经网络对本征模态函数和残差序列进行预测并集成, 得到能耗预测值; 应用 CEEMD-UWOA-Elman 混合模型对上海某大型公共建筑能耗进行短期预测, 结果显示混合模型获得很好的预测效果。

关键词: 改进的鲸鱼优化算法; 互补集合经验模态分解; 建筑能耗; 预测

Building Energy Consumption Prediction Based on Hybrid Model Constructed by Improved Whale Algorithms

Wang Ru, Song Shuang, He Jia

(College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: Building energy consumption data has non-stationary and nonlinear characteristics. A single prediction model is difficult to predict accurately, and a new hybrid model for short-term prediction of building energy consumption is proposed. Complementary ensemble empirical mode decomposition (CEEMD) is utilized to decompose volatility energy data into a set of intrinsic mode functions and a residual sequence. Based on reverse learning, differential evolution algorithm and control parameters, the Whale Optimization Algorithm (WOA) is upgraded to effectively solve the problem of premature convergence and local optimality, and the upgraded whale optimization algorithm (UWOA) is proposed. UWOA is utilized to optimize the weights and thresholds of the Elman neural network. The optimized Elman neural network predicts and integrates the intrinsic mode functions and the residual sequence, and then the energy prediction is obtained. The CEEMD-UWOA-Elman hybrid model is used to predict the energy consumption of a large public building in Shanghai. The results show that the hybrid model has a good prediction effect.

Keywords: upgraded whale optimization algorithm; complementary ensemble empirical mode decomposition; building energy consumption; prediction

0 引言

为满足建筑使用阶段, 建筑能耗合理分配与数据科学分析的需求, 对建筑能耗进行短期预测是日后节能工作的前提与基础。因此, 对建筑能耗短期预测方法的探索, 无论是从经济利益还是政府所提倡的绿色建筑理念角度出发, 都具有实际意义。建筑能耗受多方面因素影响, 如室外温湿度、人员感知行为、设备运行状况、建筑围护结构热工性等。由于其影响因素广泛、复杂且数据波动明显, 导致使用单一模型所得预测值与实际值有很大偏差。近年来, 随着大数据领域的发展, 在建筑能耗领域的科研人员主要是通过机器学习 (machine learning, ML) 方法^[1-3]进行探索。ML 方法主要包括支持向量机^[4-7]与人工神经网络^[8-11]。Caleb Robinson 等^[1]对机器学习部分主流模型进行建模, 并

应用美国能源信息管理局 (EIA) 所公布的商业建筑能耗数据进行训练, 最终显示极端梯度提升模型 (XGBoost) 表现最为良好, 可决系数为 0.82, 但原作者只采用了单一模型进行预测导致精度不足, 且实验中数据质量要求严格, 使得很难应用于实际; 马等^[5]运用支持向量机对中国华南地区建筑进行预测, 使用网格搜索法来确定支持向量机和两个参数, 同时选取国内的生产总值、家庭消费水平等多个经济因素作为输入, 最后与真实值比较验证了模型实用性; M. A. Rafe Biswas^[9]等运用 Levenberg-Marquardt 与 OWO-Newton 混合算法优化 BP 神经网络模型并对 TxAIRE 研究室所收集的能耗数据进行预测, 分别使用 Levenberg-Marquardt、OWO-Newton 算法独立优化神经网络, 最终显示混合算法优化结果与真实值较为贴近, 但其模型拟合优度普遍较低。

由于建筑能耗数据与风速、电力负荷等数据都具有非线性、波动性的特点, 随着人们对预测精度要求的提高, 混合模型被提出并得到了应用。孙等^[12]利用 MRSVD 对碳价数据进行分解, 再利用改进的元启发式算法对极限学习

收稿日期: 2019-08-05; 修回日期: 2019-08-29。

基金项目: 国家自然科学基金(51278400)。

作者简介: 王茹 (1968-), 女, 江苏丰县人, 教授, 硕士研究生导师, 主要从事建筑能耗、BIM 方向的研究。

机进行优化, 构建混合模型对碳价进行预测; 蒋等^[13]通过快速集成经验模态分解 (FEEMD) 将电价数据分解, 同时利用量子旋转门对智能算法进行优化, 通过使用改进算法优化径向基神经网络 (RBF) 对电价进行了预测。以上学者利用混合模型在不同领域进行预测研究, 其模型都取得了良好的预测结果, 对混合模型应用于建筑能耗预测领域提供了参考。

针对建筑能耗序列波动明显、非线性程度较大的特点, 提出一种面向建筑能耗短期预测的新型混合模型 CEEMD-UWOA-Elman。本文内容主要包括: 1) 使用 CEEMD 对具有明显波动和非线性大的能耗数据进行分解; 2) 利用反向学习、差分进化算法并引入控制参数 λ 对鲸鱼优化算法 (WOA) 进行改进, 有效解决了算法早熟收敛与陷入局部最优的问题, 并提高算法精度, 提出改进的鲸鱼优化算法 UWOA (upgraded whale optimization algorithm, UWOA), 使用 6 个基准测试函数进行仿真实验, 验证算法有效性; 3) 利用改进的鲸鱼优化算法 (UWOA) 优化 Elman 神经网络的阈值、权值, 提出 CEEMD-UWOA-Elman 混合模型; 4) 利用 CEEMD-UWOA-Elman 混合模型对上海某大型公共建筑能耗进行短期预测, 结果显示混合模型获得很好的预测效果。

1 方法与改进

1.1 互补集合经验模态分解 (CEEMD)

互补集合经验模态分解 (CEEMD) 是集合经验模态分解 (EEMD)^[14] 的升级版。CEEMD 引入自适应白噪声, 不但有效解决了 EMD 产生的模态混叠现象, 同时克服了 EEMD 加入白噪声后, 数据分解失去完整性、产生重构误差的缺点, 更加适用于非线性信号分析。CEEMD 处理建筑能耗信号过程如下:

1) 原始能耗信号 $x(t)$ 中加入自适应白噪声 $w^i(t)$, I 次实验后得到信号 $x^i(t)$, 对其进行 EMD 分解并将分解后的分量取平均, 产生第一个模态分量:

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

式中, $i = 1, 2, \dots, I$ 为加入白噪声的次数; $r_1(t) = x(t) - \overline{IMF}_1(t)$ 表示第一个模态分量的残差信号。

2) 算法定义 $E_k(\cdot)$ 为 EMD 产生的第 k 个 IMF 算子, ϵ_k 表示第 k 个信噪比。则有信号 $r_1(t) + \epsilon_1 E_1(w^i(t))$, 并对其分解, 可得到第二个模态分量:

$$\overline{IMF}_2(t) = \frac{1}{I} \sum_{i=1}^I E_1[r_1(t) + \epsilon_1 E_1(w^i(t))] \quad (2)$$

3) 重复步骤 2) 对其余分量进行求解, 直至分量无法进行 EMD 分解时结束。最终原始信号表示为:

$$x(t) = \sum_{i=1}^k \overline{IMF}_i(t) + R(t) \quad (3)$$

式中, $R(t)$ 为信号分解后产生的残差分量;

通过以上的步骤对建筑能耗数据进行分解, 利用神经网络对分解得到的 IMF 分量与残差分量 $R(t)$ 进行预测、

集成得到最终的预测值。

1.2 Elman 神经网络 (ENN)

由于建筑能耗预测研究对象是历史时间序列, 所以记忆功能对于处理时间信息至关重要。Elman 神经网络作为典型的动态局部递归神经网络, 除了拥有 BP 神经网络的三层结构, 其最大的特点是添加了承接层 (可视为隐含层的延迟算子) 使 ENN 具有了强大的记忆能力。在网络中添加承接层神经元, 引入内部反馈机制, 提升了网络本身的动态信息处理能力。

本文案例分析中, 选用相对成熟的自适应 lr 动量梯度下降法作为 Elman 神经网络训练算法; 选取环境温湿度、往日能耗值等因素作为网络输入, 将输入层神经元个数大小设定为 10; 隐含层神经元个数对神经网络的性能至关重要, 首先通过 Kolmogorov 定理^[15] 寻找到合适的理论值, 再经过试凑法选取隐含层神经元个数为 21; 承接层与隐含层神经元个数相同; 输出为所预测的能耗值, 即输出层神经元为 1。

1.3 经典鲸鱼优化算法 (WOA)

鲸鱼优化算法 (WOA)^[16] 是 Mirjalili 和 Lewis 受座头鲸的狩猎行为启发, 提出的一种新的群体智能算法。原作者通过将 WOA 与其他几个应用广、先进性强的自然启发算法, 共同应用于 29 个基准函数与 6 个结构设计问题上, 结果证实了 WOA 的先进性。算法共分为包围猎物、气泡网捕食、探索新猎物三步进行寻优, 算法具体步骤如下:

1) 包围猎物:

WOA 主要模仿鲸鱼在捕食过程中通过声纳感知并环绕逼近猎物的行为, 将当前迭代次数中适应度最优的鲸鱼位置视为猎物位置, 其他鲸鱼通过不断更新自己位置来包围猎物, 数学模型如下:

$$X(t+1) = X^* - A \cdot |X_t - C \cdot X^*| \quad (4)$$

$$A = 2a \cdot r - a \quad (5)$$

$$C = 2 \cdot r \quad (6)$$

式中, X^* 为本次迭代最优解的位置向量; X_t 为鲸鱼个体的位置向量; A 与 C 为系数向量, r 为 (0, 1) 之间的随机数; a 在整个寻优阶段从 2 逐渐递减到 0。

2) 气泡网捕食:

WOA 构建的气泡网攻击方式, 主要由收缩环绕与螺旋更新这两种策略组成, 其中螺旋更新依据公式 (7) 进行移动:

$$X(t+1) = D \cdot e^{bl} \cdot \cos(2\pi l) + X^* \quad (7)$$

式中, $D = |X^* - X_t|$ 为鲸鱼个体到猎物的距离, l 为 $[-1, 1]$ 内的一个随机数, b 为常数, 用于定义鲸鱼运动螺旋形式。

在 WOA 中, 由于鲸鱼螺旋运动与收缩包围猎物同时进行, 所以算法假定鲸鱼各有百分之五十的概率来进行选择哪种方式靠近猎物, 模型如式 (8) 所示:

$$X(t+1) = \begin{cases} X_t - A \cdot |X_t - C \cdot X^*| & \text{if } p < 0.5 \\ D \cdot e^{bl} \cdot \cos(2\pi l) + X^* & \text{if } p \geq 0.5 \end{cases} \quad (8)$$

式中, p 为 $[0, 1]$ 的随机数。

3) 探索新猎物:

当 $|A| < 1$ 时, 鲸鱼进行局部搜索, 并根据式 (4) 更新鲸鱼位置坐标; 当 $|A| \geq 1$ 进行全局搜索, 算法随机选择鲸鱼迫使其选择更优的猎物, 以此增强算法的全局搜索能力, 根据公式 (10) 进行鲸鱼位置坐标更新, 其中 X_{rand} 为当前迭代次数中任意一只鲸鱼, D' 为随机鲸鱼与其寻找到的更优猎物的距离向量。数学模型表达如下:

$$D' = |X_i - C \cdot X_{rand}| \quad (9)$$

$$X(t+1) = X_{rand} - A \cdot D' \quad (10)$$

1.4 改进鲸鱼优化算法 (UWOA)

1.4.1 反向学习 (OBL)

反向学习理论 (OBL)^[17] 最开始是由 Tizhoosh 在元启发式算法优化领域提出并应用。反向学习通过求取可行解的反向解以增加搜索空间的利用率, 来提高收敛于最优解的概率。在 OBL 中, 其核心思想是利用公式 (11) 得出实数 x 的反向数 \bar{x} , 式中 u 和 l 分别代表搜索空间的上限和下限。在多维空间中, 即 $x_i \in R^n$, 点 $O = (x_1, x_2, \dots, x_n)$, 则其反向解^[18] 为 $\bar{O} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n)$ 由公式 (12) 得出。其中, γ 为 $[0, 1]$ 区间的一个随机数。

$$\bar{x} = u + l - x \quad (11)$$

$$\bar{O} = \gamma * (\bar{u}_i + \bar{l}_i) - \bar{x}_i \quad (12)$$

1.4.2 差分进化 (DE)

本文将具有良好探索能力的 DE 整合到 WOA 中, 来完善 WOA 开发算法空间的能力。DE 通过对当前最优解进行变异和交叉来产生新个体, 如果产生的新个体比相应的最优解适应度更好, 则它就会被新个体所取代。

同时, 引入参数 λ 来调节算法的局部寻优与全局搜索能力, λ 由公式 (13) 进行调节, 随着迭代次数的增加, λ 的值从 1 减少到 0。因此, 在迭代初期算法全局搜索能力提高, 随着迭代次数的增加, 算法局部寻优能力增强。UWOA 算法伪代码见 (算法 1)。

$$\lambda = 1 - \frac{t}{t_{max}} \quad (13)$$

算法 1: UWOA 算法

- 1: 生成初始种群 $Z_i (i=1, 2, \dots, N)$
- 2: 使用反向学习得种群 $\bar{Z}_1 (i=1, 2, \dots, N)$
- 3: 评估 Z_i 和 \bar{Z}_1 中鲸鱼个体的适应度, 并使 \bar{X}^* 表示最优鲸鱼个体
- 4: 从 Z_i 和 \bar{Z}_1 中, 择优选择 N 个个体 $X_i (i=1, 2, \dots, N)$
- 5: while ($t < t_{max}$)
- 6: for $i=1$ to N do
- 7: 根据公式 (12) 反向学习, 进行位置更新
- 8: end
- 9: for $i=1$ to N do
- 10: 更新 α, A, C, l, p 的值
- 11: $j_{rand} = \text{randint}(1, n)$
- 12: for $j =$ to n do
- 13: 根据式 (13) 计算控制参数 λ 的值
- 14: if $p \leq \lambda$ then

- 15: if $\text{randreal } j [0, 1] \leq CR$ or $j = j_{rand}$ then
- 16: $U_i(j) = X^*(j) + F \times (X_{r_2}(j) - X_{r_2}(j))$
- 17: else
- 18: 选择一个随机个 X_{rand}
- 19: 根据公式 (9) (10) 更新
- 20: end if
- 21: else if $p > \lambda$ then
- 22: if $\text{randreal}_i (0, 1) \leq 0.5$ then
- 23: 根据公式 (4) 更新
- 24: else
- 25: 根据公式 (7) 更新
- 26: end if
- 27: end if
- 28: end for
- 29: 评估后代 U_i
- 30: if U_i 优越 X_i then
- 31: 更新个体 $i, X_i = U_i$
- 32: if U_i 优越于 X^* then
- 33: 更新最优个体, $X^* = U_i$
- 34: end if
- 35: end if
- 36: end for
- 37: $t = t + 1$;
- 38: end while

2 UWOA 算法性能测试

2.1 测试函数

为检验 UWOA 算法的寻优性能, 本文选取 6 个基准函数进行测试, 分别为: Sphere、Rosenbrock、Elliptic、Rastrigin、Ackley 和 Griewank 函数, 将其按照 $f_1(x) \sim f_6(x)$ 进行排列。其中, Sphere、Rosenbrock 和 Elliptic 为单峰函数, 其余三个均为多峰函数, 各个函数维数、搜索空间与最小值如表 1 所示。

表 1 测试函数

函数	维数	搜索空间	最小值
Sphere	30	$[-100, 100]$	0
Rosenbrock	30	$[-30, 30]$	0
Elliptic	30	$[-100, 100]$	0
Rastrigin	30	$[-5.12, 5.12]$	0
Ackley	30	$[-32, 32]$	0
Griewank	30	$[-600, 600]$	0

2.2 实验结果分析

本文选取参考文献[12]中所提出的 AWOA、WOA 作为对比算法与本文提出的 UWOA 进行比较。UWOA 中差分进化算法缩放因子与交叉率分别选取为 $F=0.5, CR=0.9$ 。3 种算法种群规模均设置为 30, 测试函数维度设置为 30, 每个算法单独运行 30 次, 迭代次数为 500, 并将实验结果取平均值, 使用 Matlab 2018b 进行仿真实验, 6 个测试函数的收敛精度设置为 1×10^{-8} 。选取平均值、最差结果、最优结果、收敛代数与成功率作为评价指标, 实验结果如表 2 所示。

表 2 仿真实验测试结果

函数	指标	UWOA	AWOA	WOA
f_1	平均值	0	8.2473E-288	1.86712E-70
	最差结果	0	2.4221E-286	5.60133E-69
	最优结果	0	7.0951E-303	1.33706E-85
	收敛代数	375.3667	500	500
	成功率	1	1	1
f_2	平均值	1.2098E-242	5.3704E-149	1.53467E-49
	最差结果	3.6294E-241	9.1517E-148	3.2729E-48
	最优结果	0	2.8177E-156	4.98565E-56
	收敛代数	499.8666667	500	500
	成功率	1	1	1
f_3	平均值	0	2.6938E-282	2.31079E-70
	最差结果	0	8.061E-281	5.06752E-69
	最优结果	0	2.7196E-301	3.08941E-81
	收敛代数	367.8666667	500	500
	成功率	1	1	1
f_4	平均值	0	0	5.447331018
	最差结果	0	0	163.4199305
	最优结果	0	0	0
	收敛代数	31.5	63.86666667	197.9333333
	成功率	1	1	0.966666667
f_5	平均值	8.88178E-16	8.88178E-16	3.9672E-15
	最差结果	8.88178E-16	8.88178E-16	7.99361E-15
	最优结果	8.88178E-16	8.88178E-16	8.88178E-16
	收敛代数	106.2333333	162.4666667	251.0333333
	成功率	1	1	1
f_6	平均值	0	0.016	0
	最差结果	0	0.275	0
	最优结果	0	0	0
	收敛代数	45.93333333	92.13333333	198.3333333
	成功率	1	1	1

经过整理分析表 2 的实验结果可以得出, UWOA 在函数 f_1 、 f_3 、 f_4 、 f_6 均达到了理论最优值 0, 函数 f_2 虽然没有达到理论最优值, 但与最优值 0 非常接近。其中, 在单峰函数实验中, 三个算法找到全局最优的概率均为 100%, 虽然 AWOA 相较于 WOA 算法性能有所提高, 但 UWOA 在求解速度、精度方面均优于对比算法 AWOA; 在多峰函数检测中, UWOA 在函数 f_1 和 f_6 达到了理论最优值 0, 函数 f_5 虽没有达到最优值, 但收敛精度及速度均优于对比算法。实验结果表明, UWOA 在 6 个基准函数上 30 次的检测中均能收敛成功, 且在 f_1 、 f_3 、 f_4 、 f_6 均能达到理论最优值, 展现了良好的寻优性能。

图 1 为 UWOA 与 AWOA、WOA 在 6 个基准函数收敛曲线对比图。从图中可以明显看出, AWOA 相比于

WOA 算法性能上虽有明显提升, 但 UWOA 的收敛曲线均在 AWOA 与 WOA 收敛曲线下, 精度更高且下降速度更快, 性能更优于两个比较算法。

3 案例分析

3.1 负荷预测流程

本节中, 利用 CEEMD-UWOA-Elman 混合模型对上海某大型公共建筑电力能耗进行预测。随机选取 190 组用电数据用做模型训练样本, 余下的 24 组作为测试样本对模型精度进行检测。对选定的建筑能耗数据进行 CEEMD 分解, 如图 2 所示, IMF1 至 IMF6 为经过 CEEMD 分解后的频率, 残差 R 代表长期趋势。由于建筑设备的电力能耗量易受外界环境影响, 特别是能耗占比较大的空调设备, 其运行受天气因素干扰严重。因此本文选取是否为休息日、室外干球温度、室外相对湿度, 将文献[19]选择的输入作为参考, 最终确定输入数据特征的维数为 10。

3.2 结果分析

对原始电力能耗序列进行 CEEMD 分解后, 将分解的子序列输入到经 UWOA 优化后的 Elman 神经网络进行预测。图 3 为混合预测模型和其余 3 种算法对 Elman 神经网络优化后, 预测值与真实值结果对比图。可以明显看出本文所提出混合模型对测试样本完成了很好的拟合效果。较其他模型进行对比, 预测曲线与真实值预测曲线相反方向趋势更小, 具有更优秀的预测效果。

本文中实例预测精度采用可决系数 (R^2)、均方根误差 (RMSE)、平均绝对百分误差 (MAPE) 作为性能评价指标, 其运算形式如公式 (14) ~ (16) 所示, 表 3 为 3 个性能评价指标对比。结果显示本文所提出的 CEEMD-

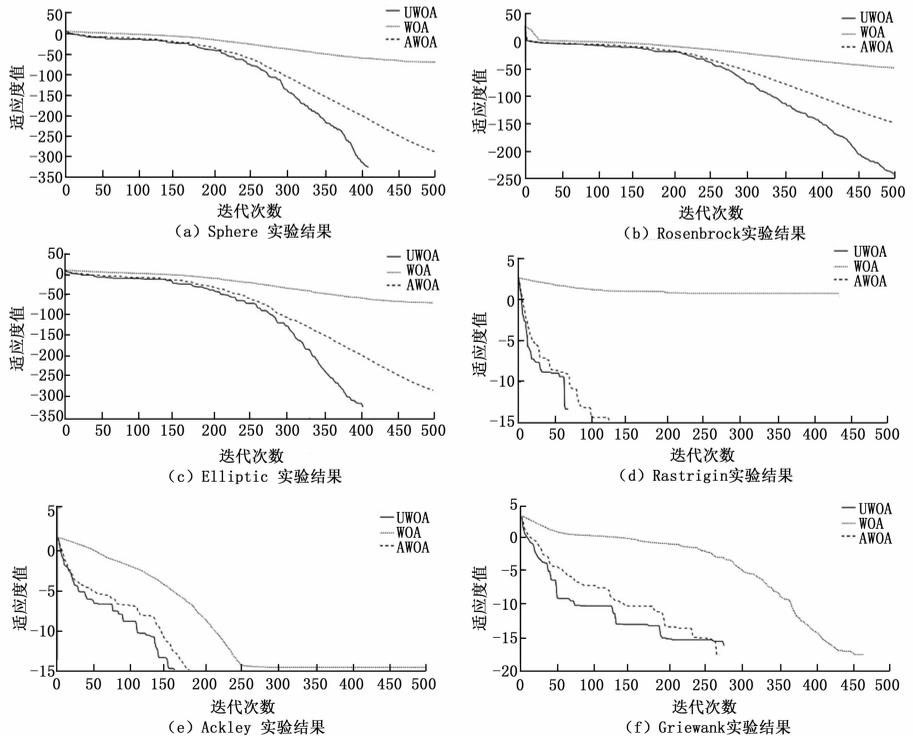


图 1 算法收敛曲线图

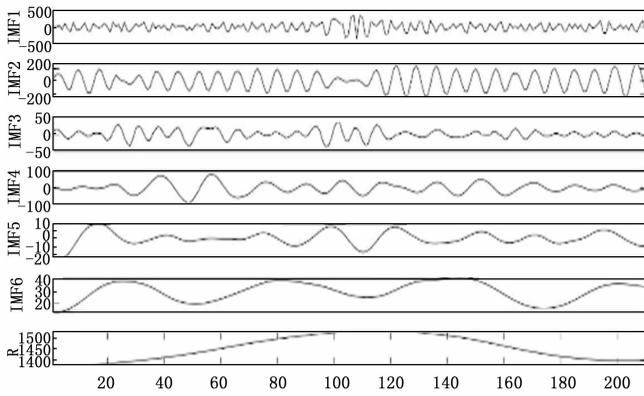


图 2 不同频率的 IMF 趋势

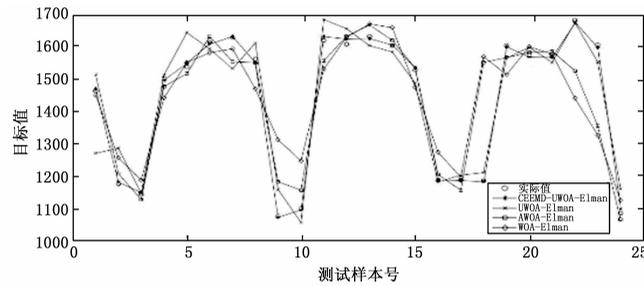


图 3 预测值与实际值对比

UWOA-Elman 三个性能评价指标均优于其它 4 种模型, 表明了改进算法的有效性和混合模型的先进性; 同时本文提出的 CEEMD-UWOA-Elman 预测模型在其性能评价指标中, $MAPE=1.104\%$, $RMSE=19.527$ 均低于其他模型, 说明更贴近真实值, 误差更小, 可决系数为 0.987, 可以很好的反应建筑能耗预测目标时间内的能耗变化情况。

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|X_i - \hat{X}_i|}{|X_i|} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2} \quad (16)$$

表 3 性能评价指标

模型	R^2	$RMSE$	$MAPE$
CEEMD-UWOA-Elman	0.987	19.527	1.104
UWOA-Elman	0.955	66.804	3.542
AWOA-Elman	0.929	105.322	4.422
WOA-Elman	0.909	134.526	6.706

4 结论

本文提出一种 CEEMD-UWOA-Elman 混合预测模型, 并将其应用于建筑能耗预测领域。首先通过运用 CEEMD 对波动明显的建筑能耗数据进行分解; 其次采用

UWOA 优化 Elman 神经网络的权值与阈值; 最后利用 UWOA-Elman 对 CEEMD 所分解出来的子序列进行预测并得到最终的能耗预测值。为检验新模型的预测能力, 对上海某大型公共建筑能耗数据进行预测, 结果通过可决系数、均方根误差、平均绝对百分比误差, 三个性能评价指标进行对比分析, 表明本文提出的方法具有良好的预测性能。同时, 在日后的研究中还可以考虑其他影响建筑能耗的因素作为输入变量以提高模型的整体预测性能; 也可将此模型应用于碳价、风速、电价等具有非线性且波动大的序列中进行预测研究。

参考文献:

- [1] Robinson C, Dilkina B. Machine learning approaches for estimating commercial building energy consumption [J]. Applied Energy, 2017, 208 (15): 889-904.
- [2] Touzani S, Ravache B. Statistical change detection of building energy consumption: applications to savings estimation [J]. Energy and Buildings, 2019, 185 (15): 123-136.
- [3] Mocanu E, Nguyen P H. Deep learning for estimating building energy consumption [J]. Sustainable Energy, 2016, 6: 91-99.
- [4] Amasy K. Building lighting energy consumption prediction for supporting energy data analytics [J]. Procedia Engineering, 2016, 145: 511-517.
- [5] Ma Z T, Ye C T. Support vector regression for predicting building energy consumption in southern China [J]. Energy Procedia, 2019, 158: 433-438.
- [6] Ma Z T, Ye C T. Applying support vector machines to predict building energy consumption in China [J]. Energy Procedia, 2018, 152: 780-786.
- [7] Jung H C, Kim J S. Prediction of building energy consumption using an improved real coded genetic algorithm based least squares support vector machine approach [J]. Energy and Buildings, 2015, 90: 76-84.
- [8] 刘爱军, 尹明. 基于 GA-LM-BP 神经网络的锂离子电池预测研究 [J]. 计算机测量与控制, 2018, 26 (7): 44-48.
- [9] RafeBiswas M A, Robison M D, Fumo N. Prediction of residential building energy consumption: A neural network approach [J]. Energy, 2016, 117, Part1: 84-92.
- [10] Fan C, Wang J Y. Assessment of deep recurrent neural network based strategies for short-term building energy predictions [J]. Applied Energy, 2019, 236: 700-710.
- [11] Zheng Z, Chen H N. Spatial granularity analysis on electricity consumption prediction using LSTM recurrent neural network [J]. Energy Procedia, 2019, 158: 2713-2718.
- [12] Sun W, Zhang C C. Analysis and forecasting of the carbon price using multi-resolution singular value decomposition and extreme learning machine optimized by adaptive whale optimization algorithm [J]. Applied Energy, 2018, 231: 1354-1371.
- [13] 蒋锋, 何佳琪, 曾志刚, 等. 基于分解-优化-集成学习方法电价预测 [J]. 中国科学: 信息科学, 2018, 48: 1300-1315.