

doi:10.11835/j.issn.2096-6717.2019.021



基于改进 PSO-BP 神经网络的冰蓄冷空调 冷负荷动态预测模型

杨熊^a, 于军琪^a, 郭晨露^a, 华宇剑^b, 赵安军^a

(西安建筑科技大学 a. 信息与控制工程学院; b. 陕西省新型城镇化与人居环境研究院, 西安 710055)

摘要:当前多数冰蓄冷空调冷负荷动态预测方法中,由于模型输入变量与输出结果相关性差、信息冗余度高等原因,导致多数预测模型在预测精度和收敛速度方面都未达到理想的预测效果,因此,提出一种改进的 PSO-BP 神经网络算法预测大型公共建筑的冷负荷。对于输入变量与输出结果采用灰色关联度分析,消除样本输入变量对数的耦合性,确定影响冰蓄冷空调系统冷负荷的关键性因素,将其作为输入变量,预测冰蓄冷空调系统动态冷负荷。结果表明: T 时刻室外空气温度、 $T-1$ h 时刻室外空气温度、 T 时刻室外空气湿度、 T 时刻太阳辐射强度、 $T-1$ h 时刻太阳辐射强度、 $T-1$ h 时刻空调冷负荷是影响 T 时刻冰蓄冷空调系统冷负荷的关键因素,并以此作为预测模型的输入变量。相对于传统 PSO-BP 神经网络全输入变量预测算法,该模型预测结果精确度更高、收敛速度更快。

关键词:空调;预测算法;PSO-BP 神经网络;灰色关联性分析

中图分类号: TU831.2 **文献标志码:** A **文章编号:** 2096-6717(2019)01-0168-07

Dynamic load forecasting model of ice storage air conditioning based on improved PSO-BP neural network

Yang Xiong^a, Yu Junqi^a, Guo Chenlu^a, Hua Yujian^b, Zhao Anjun^a

(a. School of Information and Control Engineering; b. Institute of New Urbanization and Habitat Environment, Shaanxi Province, Xi'an University of Architecture and Technology, Xi'an 710055, P. R. China)

Abstract: At present, most of the dynamic prediction methods of ice storage air conditioning cooling load showed poor precision and slow convergence speed, due to bad correlation between model input variables and output results, high information redundancy. This paper proposes an improved PSO-BP neural network optimization algorithm to predict the cooling load of large public buildings. For the input variables and the output results, the degree of grey correlation analysis is used to eliminate the chance of the logarithm of the samples input variables, and the key factors affecting the cold load of the ice storage air conditioning system are determined as input variables to predict the dynamic cooling load of the ice storage air conditioning

收稿日期: 2018-03-04

基金项目: 国家重点研发计划(2017YFC0704100); 陕西省教育厅产业化培育项目(17JF015)

作者简介: 杨熊(1990-), 男, 主要从事智能建筑与建筑节能、智能算法研究, E-mail: 18691811913@163.com。

于军琪(通信作者), 男, 教授, 博士生导师, E-mail: junqiyu@126.com。

Received: 2018-03-04

Foundation item: National Key R & D Program (2017YFC0704100); Shaanxi Provincial Department of Education Industrialization Cultivation Project (17JF015)

Author brief: Yang Xiong(1990-), main research interests: intelligent building and building energy saving and intelligent algorithm, E-mail: 18691811913@163.com.

Yu Junqi(corresponding author), professor, doctoral supervisor, E-mail: junqiyu@126.com.

system. The results show that the key factors of the cooling load of ice storage air conditioning system include the outdoor air temperature at T h, the outdoor air temperature at $T-1$ h, the outdoor air humidity at T h, the solar radiation intensity at T h, the solar radiation intensity at $T-1$ h, and the air-conditioning cooling load at $T-1$ h. Therefore, these key factors act as the input variables of the prediction model which show higher accuracy and faster convergence speed than the traditional PSO-BP network model of full-variable prediction method.

Keywords: air conditioning; prediction algorithms; PSO-BP neural network; gray correlation analysis

随着中国社会经济的快速发展,能源短缺和环境恶化现象日益突出,沉重的能源负担已成为阻碍经济可持续发展的重要桎梏。其中,建筑能耗约占全社会总能耗的 30%^[1],在所有建筑中,大型公共建筑因其舒适度要求高、人流量大、空调系统运行时间长等原因,已成为建筑能耗中的“巨无霸”,其空调系统单位建筑面积能耗约为城镇建筑的 5 倍^[2]。作为缓解这种紧张局面的一种有效方式,冰蓄冷空调系统利用水/冰相变潜能储存能量,使用夜间低价电制冰蓄冷,白天用电高峰融冰释冷,以满足建筑物的负荷需求,不仅对电网的电力负荷具有移峰填谷的作用,同时,也降低了用户空调系统的运行费用。合理匹配谷段及峰段电价时间内制冷机组供冷和蓄冰装置融冰供冷是冰蓄冷空调系统优化控制的核心问题,其中,准确的冷负荷动态预测数据更是冰蓄冷空调系统节能优化的首要因素。

当前,建筑冷负荷预测方法主要有回归分析法、仿真模拟法和机器学习法。回归分析法主要包括多元线性回归模型(MLR)^[3]、自回归(AR)模型^[4]。由于 MLR 模型在影响建筑冷负荷的多变量方面具有严重的非线性,因此,预测精度相对较低。AR 模型输入变量仅为建筑冷负荷的历史数据,而没有考虑其他因素,预测精度也很难满足实际要求。常用的建筑冷负荷模拟软件有 TRNSYS^[5-6]、ESP-r^[7-8]和 EnergyPlus^[9-10]等,其在冷负荷预测过程中软件程序效率较低,主要表现在:1)系统模型的建立需要花费较长的时间,并且模型也必须根据实际运行结果进行验证和完善,才能产生高精度的输出;2)由于模拟软件通常用于空调系统的前期设计阶段,因此,在系统运行阶段难以提供准确、实时的指导控制;3)建模过程中参数设置对建模人员的专业化、工程经验均要求高。综上所述,传统的仿真软件程序不适合用于实际的系统管理。随着人工智能 AI (Artificial Intelligence) 的快速发展,其中,BP(Back

Propagation)神经网络以其突出的非线性映射、自适应、容错性强等特点,广泛地应用于建筑冷负荷的动态预测^[11-15]。然而,BP神经网络具有局部最优、收敛速度慢、对训练数据依赖性大的缺陷,往往又阻碍了其在实际工程中的应用。多数研究者采用粒子群优化算法 PSO (Particle Swarm Optimization) 的全局搜索能力优化 BP 神经网络,极大地避免模型陷入局部最优的缺陷。然而,由于模型输入变量与输出变量相关性差、冗余度高导致的模型预测精度差的缺陷仍然没有得到良好解决^[16-17]。

笔者在传统 PSO-BP 神经网络全变量预测模型的基础上,采用灰色关联度分析法对模型输入变量预处理,剔除相关性较低的因子,采用与输出结果关联度高的因子作为模型输入变量预测大型公共建筑冰蓄冷空调系统动态冷负荷。研究表明,该改进模型相对于传统 PSO-BP 神经网络全输入变量预测模型在预测精度、收敛速度方面均有较大的提高,满足工程实际应用需求。

1 大型公共建筑冷负荷动态预测模型

1.1 灰色关联度分析法

灰色关联度分析法是一种多因素统计分析方法,以各因素的样本数据为依据来描述输入因素对输出结果影响的强弱、大小和次序^[18]。若输入变量与输出结果变化的趋势、速度基本一致,则它们之间的关联度较大;反之,关联度较小。该方法避免了由于输入变量不对称带来的损失,并且对数据要求较低,工作量较少,广泛用于数据预处理。

1.2 PSO-BP 神经网络算法

PSO-BP 神经网络将粒子群优化算法引入 BP 神经网络,利用 PSO 算法的全局搜索特性和 BP 算法快速局部搜索能力,达到良好的预测效果^[19-21]。PSO-BP 神经网络模型,将网络权值和阈值映射为种群粒子编码,以样本输出值与期望值之差的绝对

值之和为粒子适应度函数,通过反复迭代,最终获得最优粒子,解码后得到 BP 神经网络全局最优权值和阈值。

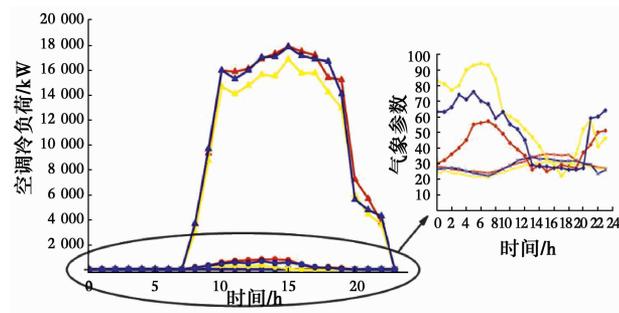
2 基于改进 PSO-BP 神经网络的大型公共建筑冷负荷动态模型

2.1 实验数据来源与分析

实验数据来源于西安赛格国际购物中心,该建筑物高 40.6 m,总建筑面积 25 万 m²,商业面积 20 万 m²,分为地下两层,地上八层,建筑空调面积 18.76 万 m²,夏季空调采用部分蓄冷的冰蓄冷空调系统。

冰蓄冷空调冷负荷预测训练样本的输入层节点通常为 T 时刻室外空气温度、湿度、太阳辐射强度、室外风速^[22-25],考虑到太阳辐射、室外温度会导致建筑空调冷负荷存在严重的滞后现象,因此,在预测模型中还加入了 $T-1$ h 时刻室外空气温度、太阳辐射强度^[26]。考虑到空调冷负荷的时间序列性,相关研究还加入了 $T-1$ h 时刻空调冷负荷、 $T-2$ h 时刻空调冷负荷、 $T-3$ h 时刻空调冷负荷以及 $T-24$ h 时刻空调冷负荷作为模型输入变量。输出层节点为 T 时刻空调预测冷负荷。

实验以 6 月、7 月空调系统逐时冷负荷数据、室外干球温度数据、室外空气湿度以及太阳辐射强度等变量做为训练数据,采用 8 月份数据对模型进行验证分析,如图 1 所示。3 个月的室外气象参数与空调冷负荷均具有强烈的关联性,3 个月某日中空冷负荷随着室外气象参数的变化发生相应的变化,室外温度、太阳辐射强度与空调冷负荷正相关,室外湿度与空调冷负荷负相关。



注: — 6月份某日冷负荷 — 6月份某日温度 — 6月份某日湿度 — 6月份某日太阳辐射强度
— 7月份某日冷负荷 — 7月份某日温度 — 7月份某日湿度 — 7月份某日太阳辐射强度
— 8月份某日冷负荷 — 8月份某日温度 — 8月份某日湿度 — 8月份某日太阳辐射强度

图 1 6 月、7 月、8 月空调冷负荷与室外气象参数曲线图
Fig. 1 Air-conditioning cooling load and outdoor meteorological parameters in June, July and August

2.2 输入变量关联性分析

采用灰色关联度分析法,计算输入变量与输出结果间灰色关联度,具体步骤如下。

step1:采用式(1),建立相关指标的原始数据矩阵 x_i ;

$$x_i = (x_i(0), x_i(1), x_i(2), \dots, x_i(23)) \quad (1)$$

式中: $x_i(0), x_i(1), x_i(2), \dots, x_i(23)$ 分别表示第 i 个变量在 0:00—23:00 时刻的值。

step2:采用式(2),建立初始化变化矩阵 x'_i ;

$$x'_i = (x_i(0)/x_i(0), x_i(1)/x_i(0), x_i(2)/x_i(0), \dots, x_i(23)/x_i(0)) = (x'_i(0), x'_i(1), x'_i(2), \dots, x'_i(23)) \quad (2)$$

step3:采用式(3),求差序列 $\Delta_{oi}(k)$;

$$\Delta_{oi}(k) = \text{abs}(x_o^i(k) - x'_i(k)) = (\Delta_{oi}(0), \Delta_{oi}(1), \dots, \Delta_{oi}(23)) \quad (3)$$

Step4:采用式(4)、式(5),计算关联系数 $\xi_{oi}(k)$ 和灰色关联度 γ_{oi} ;

$$\xi_{oi}(k) = \frac{\min_i \min_k \Delta_{oi}(k) + \varphi \max_i \max_k \Delta_{oi}(k)}{\Delta_{oi}(k) + \varphi \max_i \max_k \Delta_{oi}(k)} \quad (4)$$

$$\gamma_{oi} = \frac{1}{23} \sum_1^{24} \xi_{oi}(k) \quad (5)$$

空调冷负荷动态预测模型各输入变量与 T 时刻空调冷负荷灰色关联度如表 1。

表 1 各影响因子与 T 时刻空调冷负荷灰色关联度
Table 1 The impact of various factors and T time air conditioning cooling load gray correlation

变量	灰色关联度	变量	灰色关联度
T 时刻室外空气温度	0.952 7	T 时刻相对湿度	0.896 3
$T-1$ h 时刻室外空气温度	0.983 2	$T-24$ h 时刻空调冷负荷	0.791 3
T 时刻太阳辐射强度	0.897 7	$T-3$ h 时刻空调冷负荷	0.772 4
$T-1$ h 时刻太阳辐射强度	0.923 4	$T-2$ h 时刻空调冷负荷	0.821 4
T 时刻室外风速	0.663 5	$T-1$ h 时刻空调冷负荷	0.942 7

由上述分析可知, T 时刻室外风速与 T 时刻空调冷负荷关联度较小,关联度系数仅为 0.663 5,这是由于多数大型公共建筑采用封闭式的外围护结构,没有与外界形成自然通风,室内形成相对封闭的环境,因此,室外风速对空调系统冷负荷的影响较

小; $T-24$ h 时刻空调冷负荷与 T 时刻空调冷负荷关联度为 0.791 3, 由于前一天与当天可能会存在较大的气象参数差异, 因此, 相同时刻的空调冷负荷就会存在较大差异; $T-3$ h 时刻空调冷负荷、 $T-2$ h 时刻空调冷负荷相对于 $T-1$ h 时刻空调冷负荷与 T 时刻空调冷负荷关联度较低, 为了降低仅由于历史冷负荷对 T 时刻冷负荷的耦合作用, 仅采用关联度较高的 $T-1$ h 时刻空调冷负荷作为历史冷负荷影响 T 时刻预测冷负荷的关键因素; T 时刻室外空气温度、湿度、太阳辐射强度与 T 时刻空调冷负荷表现出较高的关联性, 这与多数大型公共建筑冷负荷影响因素研究的结论一致^[4,7,11,15,27-28]。由于室外空气温度、太阳辐射强度对大型公共建筑空调冷负荷存在严重的滞后性, 因此, $T-1$ h 时刻室外空气温度、太阳辐射强度与 T 时刻空调冷负荷关联度也较高。

综上分析, 确定 T 时刻室外空气温度、 $T-1$ h 时刻室外空气温度、 T 时刻室外空气湿度、 T 时刻太阳辐射强度、 $T-1$ h 时刻太阳辐射强度、 $T-1$ h 时刻空调冷负荷为影响 T 时刻空调冷负荷的关键因素。

2.3 基于 PSO-BP 神经网络模型进行大型公共建筑动态冷负荷预测

基于上述对预测模型输入变量的分析, 实验采用 3 层 BP 神经网络结构, 输入层神经元数为 6, T 时刻空调冷负荷数据为输出层, 故输出层神经元数为 1, 隐含层因子数由经验式(6)得出为 13。隐含层节点采用 tansig 转移函数, 输出层节点采用 purelin 转移函数。

$$m = 2n + 1 \quad (6)$$

式中: m 为隐含层神经元个数; n 为输入层神经元个数。

1) 由于神经网络训练函数的活性范围为 $[0, 1]$, 采用式(7)离差标准化对输入数据进行处理。

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

2) 初始化粒子群的规模, 包括种群粒子个数 N 、粒子个体长度 D 、粒子的初始速度、位置。

试验中粒子数 N 取值为 100, 粒子个体长度 D 的计算式为

$$D = S_1 S_2 + S_2 S_3 + S_2 + S_3 \quad (8)$$

式中: S_1 、 S_2 、 S_3 分别为 BP 神经网络输入层因子数、隐含层因子数、输出层因子数。计算得 $D=105$ 。

3) 粒子适应度计算。以预测值和观测值的误差绝对值之和作为粒子适应度值 F , 计算公式为

$$F = \sum_{i=1}^n \text{abs}(y_i - o_i) \quad (9)$$

式中: n 为样本数; y_i 为样本 i 的观测值; O_i 为样本 i 的预测值。

4) 粒子适应度比较。比较规则为:

如果 $sse < p_{\text{bestfitness}}$, 则 $p_{\text{bestfitness}} = sse$, $p_{\text{best}} = x_i$; 否则 $p_{\text{bestfitness}}$ 和 p_{best} 不变。

如果 $sse < g_{\text{bestfitness}}$, 则 $g_{\text{bestfitness}} = sse$, $g_{\text{best}} = x_i$; 否则 $g_{\text{bestfitness}}$ 和 g_{best} 不变。

其中: sse 是粒子的当前适应值; $p_{\text{bestfitness}}$ 是粒子的个体最优适应值; $g_{\text{bestfitness}}$ 是种群全局最优适应值; p_{best} 是粒子个体最优值; g_{best} 是种群全局最优值; x_i 为当前计算粒子。

5) 粒子位置及速度的更新。采用式(10)、式(11)进行粒子速度及位置的更新。

$$V_{id}^{(t+1)} = uv_{id}^{(t)} + c_1 r_1 (P_{id}^{(t)} - X_{id}^{(t)}) + c_2 r_2 (P_{gd}^{(t)} - X_{id}^{(t)}) \quad (10)$$

$$x_{id}^{(t+1)} = x_{id}^{(t)} + v_{id}^{(t+1)} \quad (11)$$

式中: $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})$ 、 $V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$ 、 $P_g = (P_{g1}, P_{g2}, \dots, P_{gD})$ 分别为每一代粒子的第 d 维 ($1 \leq d \leq D$) 速度和位置, $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$, $i = 1, 2, \dots, N$, 在式(10)中, 惯性权值 u 取值 0.7, 加速因子 $c_1 = c_2 = 1.93$, 初始速度、位置采用 rand() 函数随机赋值, 最大迭代次数设为 t_{\max} 取 3 000, 最小误差 e 取 10^{-3} , 并设置粒子位置及速度的最大区间, 规则为: 若 $x_{id}^{(t+1)} > x_{\max}$, 则 $x_{id}^{(t+1)} = x_{\max}$; 若 $x_{id}^{(t+1)} < -x_{\max}$, 则 $x_{id}^{(t+1)} = -x_{\max}$ 。

6) 当前迭代次数 E_{poch} 与最大迭代次数 t_{\max} 比较, 若 $E_{\text{poch}} > t_{\max}$, 则终止算法, 当前的 g_{best} 为 BP 神经网络优化的权值和阈值, 否则跳至步骤 2), 继续下一次迭代。

3 预测结果分析

两种模型的预测结果如图 2 所示, 其中, N2 预测模型为采用本文提出的改进算法建立的模型, N1 预测模型为采用传统 PSO-BP 神经网络的全输入变量算法建立的模型。由图 2 可知, 采用 N2 预测模型的预测精度高于 N1 预测模型。为进一步得出两种预测模型误差对比, 图 3 给出了两种模型的绝对误差, 由图 3 可见, N2 预测模型的绝对误差远小于 N1 预测模型。

以 RMSPE (Root mean square percentage error) (式(12)) 均方根相对误差作为两种预测模型

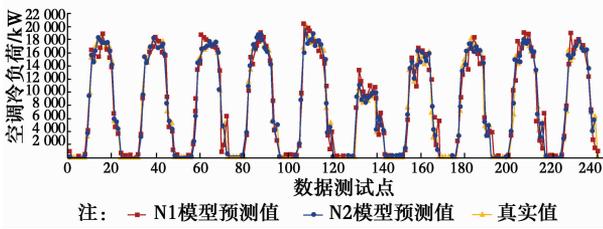


图 2 两种模型预测值与空调冷负荷真实值曲线图

Fig. 2 Two model predicted values and air conditioning cooling load actual value

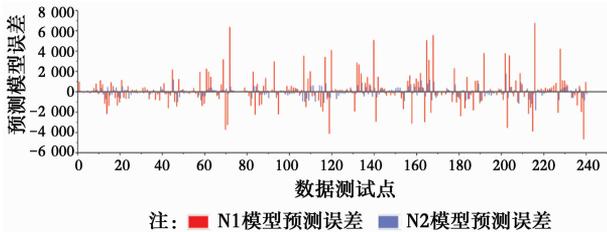


图 3 两种模型预测值与空调冷负荷真实值绝对误差柱状图

Fig. 3 The absolute errors between the real values of the air conditioning cooling load and the two models

误差评价指标,

$$RMSPE = \sqrt{\frac{1}{N} \sum_{i=0}^N (y(i) - \hat{y}(i))^2} \quad (12)$$

式中: $y(i)$ 为真实值; $\hat{y}(i)$ 为预测值; y 为空调冷负荷真实值的平均值。通过计算,N2 预测模型均方根相对误差 $RMSPE_{N2}=6.1\%$,N1 预测模型均方根相对误差 $RMSPE_{N1}=21.03\%$ 。图 4、图 5 分别为两种预测模型预测值和真实值的回归曲线图,从图中可得出,N2 预测模型相对于 N1 预测模型更加逼近真实值。在算法收敛速度方面,N1 预测模型在 1 366 步(设定训练步数为 3 000 步)达到预设误差精度;N2 预测模型到达预测精度仅为 409 步,表明 N2 预测模型相对于 N1 预测模型收敛速度更快。

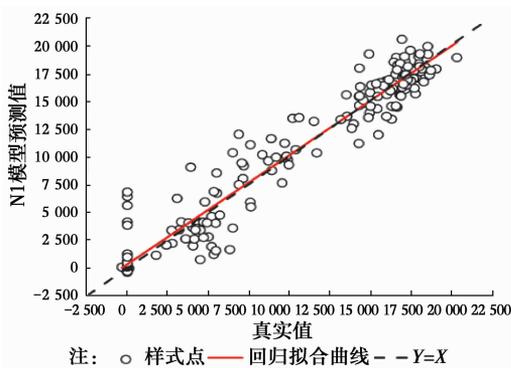


图 4 N1 模型预测值与真实值回归拟合曲线

Fig. 4 The regression fitting curve between the predicted value of N1 model and the real value

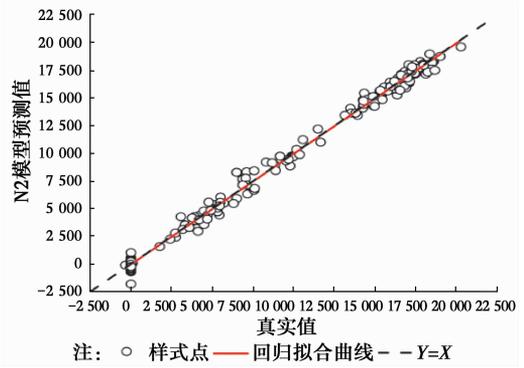


图 5 N2 模型预测值与真实值回归拟合曲线

Fig. 5 The regression fitting curve between the predicted value of N2 model and the real value

4 结论

提出一种基于改进 PSO-BP 神经网络算法,实现对冰蓄冷空调动态冷荷的准确预测,结论为:基于灰色关联性分析法,确定影响冰蓄冷空调系统冷负荷的关键因素,并以此作为 PSO-BP 神经网络预测模型的输入变量,相对于传统 PSO-BP 神经网络全输入变量预测模型,改进模型在预测精度、收敛速度方面均有较大提高,满足工程实际需求,对大型公共建筑冰蓄冷空调系统的优化运行管理有重要的应用价值。

参考文献:

[1] 清华大学建筑节能研究中心. 中国建筑节能年度发展研究报告 2017[M]. 北京:中国工业出版社,2017. Building Energy Conservation Research Center of Tsinghua University. Annual report on building energy efficiency in China 2017 [M]. Beijing: China Architecture & Building Press, 2017. (in Chinese)

[2] 薛志峰,江亿. 商业建筑的空调系统能耗指标分析[J]. 暖通空调,2005,35(1):37-42. XUE Z F, JIANG Y. Analysis of energy consumption of air conditioning system in commercial buildings [J]. Heating Ventilating & Air Conditioning, 2005, 35(1): 37-42. (in Chinese)

[3] TIBERIU C, VLAD I, BOGDAN C. Multiple regression model for fast prediction of the heating energy demand [J]. Energy & Buildings, 2013, 57: 302-312.

[4] ZHOU Q, WANG S, XU X. A grey-box model of next-day building thermal load prediction for energy-efficient control [J]. International Journal of Energy Research, 2010, 32 (15):1418-1431.

- [5] SALEH N A, ZHAI Z Q. A new validated trnsys module for simulating latent heat storage walls [J]. *Energy & Buildings*, 2015, 109 :274-290.
- [6] SAFA A A, FUNG A S, KUMAR R. Heating and cooling performance characterisation of ground source heat pump system by testing and trnsys simulation [J]. *Renewable Energy*, 2015, 83 :565-575.
- [7] BEN-NAKHI A E, MAHMOUD M A. Cooling load prediction for buildings using general regression neural networks [J]. *Energy Conversion & Management*, 2004, 45(13):2127-2141.
- [8] ĆEKON M. Accuracy analysis of longwave sky radiation models in the MZELWE module of the ESP-r program [J]. *Energy & Buildings*, 2015, 103: 147-158.
- [9] YU S, CUI Y M, XU X L. Impact of civil envelope on energy consumption based on energy plus [J]. *Procedia Engineering*, 2015, 121:1528-1534.
- [10] FUMO N, MAGO P, LUCK R. Methodology to estimate building energy consumption using energy plus benchmark models [J]. *Energy & Buildings*, 2010, 42 (12):2331-2337.
- [11] 喻伟,李百战,杨明宇.基于人工神经网络的建筑多目标预测模型[J].中南大学学报(自然科学版),2012,43 (12):4949-4955.
YU W, LI B Z, YANG M Y. Building multi-objective forecasting model based on artificial neural network [J]. *Journal of Central South University (Science and Technology)*, 2012, 43(12):4949-4955. (in Chinese)
- [12] 李祥立,王仁瑾,端木琳,等.基于BP神经网络的地板辐射供暖系统逐时负荷预测[J].暖通空调,2011,41 (12):95-98.
LI X L, WANG R J, DUAN M L, et al. Hourly heating load prediction of radiant floor heating systems based on BP neural network [J]. *Heating Ventilating & Air Conditioning*, 2011,41(12):95-98. (in Chinese)
- [13] 徐小艳,管晓宏,李黎.建筑空调系统最优停机时间预测与控制[J].西安交通大学学报,2013,47(10):31-36.
XU X Y, GUAN X H, LI L. Predicting the optimal shut-down time of heat ventilation air-conditioning and cooling system in building [J]. *Journal of Xi'an Jiaotong University*, 2013, 47 (10): 31-36. (in Chinese)
- [14] KUMAR R, AGGARWAL R K, SHARMA J D. Energy analysis of a building using artificial neural network: A review [J]. *Energy & Buildings*, 2013, 65 (4):352-358.
- [15] ESCRIVA-ESCRIVA G, ÁLVAREZ-BEL C, ROLDAN-BLAY C. New artificial neural network prediction method for electrical consumption forecasting based on building Ed-uses [J]. *Energy & Buildings*, 2011,43(11):3112-3119.
- [16] DAUT M A M, HASSAN M Y, ABDULLAH H. Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review [J]. *Renewable & Sustainable Energy Reviews*, 2017, 70:1108-1118.
- [17] 张少迪.基于 PSO-BP 神经网络的短期负荷预测算法[J].现代电子技术,2013 (12):155-158.
ZHANG S D. Algorithm of short-time load forecast based on PSO-BP neural network [J]. *Modern Electronics Technique*, 2013 (12): 155-158. (in Chinese)
- [18] 刘思峰,谢乃明.灰色系统理论及其应用[M].北京:科学出版社,2013.
LIU S F, XIE N M. Gray system theory and its application [M]. Beijing: Science Press, 2013. (in Chinese)
- [19] 李祚泳,汪嘉杨,郭淳.PSO算法优化BP网络的新方法及仿真实验[J].电子学报,2008,36 (11):2224-2228.
LI Z Y, WANG J Y, GUO C. A new method of BP network optimized based on particle swarm optimization and simulation test [J]. *Acta Electronica Sinica*, 2008, 36 (11):2224-2228. (in Chinese)
- [20] 师彪,李郁侠,于新花.改进粒子群-BP神经网络模型的短期电力负荷预测[J].计算机应用,2009,29 (4): 1036-1039.
SHI B, LI Y X, YU X H. Short-term load forecast based on modified particle swarm optimizer and back propagation neural network model [J]. *Journal of Computer Applications*, 2009, 29 (4):1036-1039. (in Chinese)
- [21] 蔡金锭,付中云.粒子群神经网络混合算法在负荷预测中的应用[J].高电压技术,2007,33(5):90-93.
CAI J D, FU Z Y. Application of particle group and neural network hybrid algorithm in load forecast [J]. *High Voltage Engineering*, 2007, 33 (5): 90-93. (in Chinese)
- [22] PAUDEL S, ELMITRI M, COUTURIER S, et al. A relevant data selection method for energy consumption prediction of low energy building based on support vector machine [J]. *Energy and Buildings*, 2017, 138: 240-256.
- [23] CHEN Y, PETER B L, CHE G. Short-term load forecasting: Similar day-based wavelet neural networks [J]. *World Congress on Intelligent Control &*

- Automation, 2008, 25 (1):3353-3358.
- [24] SUN C Y, SONG J Y, LI L F. Implementation of hybrid short-term load forecasting system with analysis of temperature sensitivities [J]. *Soft Computing*, 2008, 12(7):633-638.
- [25] TOMONBU S, HIROKAZU S, YOSHINORI T. Next-day load curve forecasting using neural network based on similarity [J]. *Electric Machines & Power Systems*, 2001, 29(10):939-948.
- [26] PAUDEL S, ELMITRI M, COUTURIER S. A relevant data selection method for energy consumption prediction of low energy building based on support vector machine [J]. *Energy & Buildings*, 2017, 138: 240-256.
- [27] YAU Y H, HASBI S. A comprehensive case study of climate change impacts on the cooling load in an air-conditioned office building in malaysia [J]. *Energy Procedia*, 2017, 143:295-300.
- [28] 王蓓蓓,朱峰,嵇文路. 中央空调降负荷潜力建模及影响因素分析[J]. *电力系统自动化*, 2016, 40(19):44-52.
WANG B B, ZHU F, JI W L. Load cutting potential modeling of central air conditioning and analysis on influencing factors [J]. *Automation of Electric Power Systems*, 2016, 40(19):44-52. (in Chinese)
- (编辑 王秀玲)
-
- (上接第 167 页)
- [10] BRUSE M, FLEER H. Simulating surface-plant-air interactions inside urban environments with a three dimensional numerical model [J]. *Environmental Modelling & Software*, 1998, 13: 373-384.
- [11] OKE T R. An algorithmic scheme to estimate hourly heat island magnitude[C]// 2nd Urban Environment Symposium, 1998, Albuquerque, NM.
- [12] OKE T R. *Boundary layer climates* [M]. London: Routledge, 2015.
- [13] China Meteorological Data Service Center [EB/OL]. [2017-06-22]. <http://data.cma.cn/en>.
- [14] YANG X, ZHAO L. Diurnal thermal behavior of pavements, vegetation, and water pond in a hot-humid city. *Buildings*, 2016, 6: 1-12.
- [15] CHOW W T L, ROTH M. Temporal dynamics of the urban heat island of Singapore [J]. *International Journal of Climatology*, 2006, 26(15): 2243-2260.
- [16] SANG J, LIU H, LIU H, et al. Observational and numerical studies of wintertime urban boundary layer [J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2000, 87(2): 243-258.
- [17] OKE T R. The energetic basis of the urban heat island [J]. *Quarterly Journal of the Royal Meteorological Society*, 1982, 108: 1-24.
- [18] THEEUWES N E, STEENEVELD G J, RONDA R J, et al. Cool city mornings by urban heat [J]. *Environmental Research Letters*, 2015:1-9.
- [19] 陈恺,唐燕. 城市局部气候分区研究进展及其在城市规划中的应用 [J]. *南方建筑*, 2017(2):21-28.
CHEN K, TANG Y. Research progress of local climate zones and its applications in urban planning [J]. *South Architecture*, 2017 (2): 21-28. (in Chinese)
- (编辑 胡玲)