

基于相似日 LM 神经网络的高校图书馆能耗预测

王茜, 于军琪

(西安建筑科技大学 建筑设备科学与工程学院, 陕西 西安 710055)

摘要: 图书馆在高校建筑中具有非常重要的地位, 有较大的节能潜力。然而, 近年来对于高校图书馆建筑节能的研究偏少, 本文通过提出一种基于相似日 LM(Levenberg-Marquardt)神经网络的高校图书馆能耗预测模型, 为高校图书馆能耗研究提供参考。以我国某高校图书馆为例, 首先通过统计分析的方法得到影响图书馆能耗较为重要的因素, 即室内人员、开放策略及气温。然后利用模糊聚类法划分相似日, 依据相似日将原有数据进行筛选。接着将处理后的数据对预测模型进行训练。最后将改进后的预测模型与原预测模型的各项指标进行对比分析。依据对比结果可知, 改进后模型的平均绝对百分比误差和均方误差分别降低了 1.28% 和 23.06, 拟合度提高了 0.042 1。

关键词: 能耗预测; 高校图书馆; 相似日; 列文伯格-马夸尔特算法

中图分类号: TU852

文献标志码: A

文章编号: 1006-7930(2022)03-0459-07

Energy consumption prediction model of a university library based on similar day selection and levenberg-marquardt neural network

WANG Qian, YU Junqi

(School of Building Services Science and Engineering, Xi'an Univ. of Arch. & Tech., Xi'an 710055, China)

Abstract: As a major part of campus buildings, libraries have great potential of energy-saving. But there are very few recent studies focused on energy conservation in university library buildings. This paper explores energy use patterns in library buildings and proposes a energy consumption prediction model for campus libraries based on Levenberg-Marquardt neural network. The model may provide reference to future energy-saving efforts. A university library building in China was chosen as the research subject. By analyzing related data, we are able to find the factors affecting energy consumption of the library most, which are occupancy, outdoor air temperature, as well as the opening hours of the library. The similar day method was employed to train the model: Through soft clustering, the energy consumption profiles of each day was put into categories which were in turn used to as inputs. Compared with the traditional LM model, the optimized LM neural network had showed a decrease in absolute percentage error and mean square error by 1.28% and 23.06, respectively, and the fitting degree had been improved by 0.042 1.

Key words: energy consumption forecast; university library; similar day; Levenberg-Marquardt algorithm

我国有近 2 000 余所高校, 其能耗在社会总能耗中的占比达到 8%^[1]。在高校内, 不同建筑类型的能耗因建筑而异^[2]。图书馆在高校建筑中必不可少, 是学生和教职人员的聚集地, 人流量大, 这导致了其能耗较高的特点, 高彪等^[3]以长三角地区某高校为例, 发现图书馆建筑在高校建筑中以仅 5% 的占地消耗了 12% 的能量。同时, 图书馆的节能潜力也很大, 有研究表明高校图书馆建筑有 6%~29% 的节能潜力^[4]。如何既能保证使用者需

求得到满足, 又可以减少图书馆的不必要能耗成为一个研究问题。Filho 等^[5]通过持续跟踪大学能耗数据, 研究了解居住者对高校能耗的影响。Wang 和 Shao 对大学图书馆进行了持续一个月的数据收集工作, 他们最终发现图书馆具有独特的能耗模式^[6]。因此, 建立高校图书馆能耗预测模型对节能降耗有重要意义。

过去常使用工程学和统计学方法对能耗进行预测^[7]。在使用工程学方法的基础上, Yik 等^[8]提

收稿日期: 2021-04-22

修改稿日期: 2022-05-23

基金项目: 陕西省社发重点基金项目(2017ZDL-SF-16-5, 2017ZDCXL-SF-03-02)

第一作者: 王茜(1996—), 女, 硕士生, 主要研究方向: 智能建筑。E-mail: 781871461@qq.com

通信作者: 于军琪(1969—), 男, 教授, 博导, 主要研究方向: 智能建筑。E-mail: junqiyu@126.com

出了更加简单准确的建筑的冷负荷模型。2018 年来自伊朗的 Mohammad Sepehr 及其同事在对当地一百多所建筑的能耗数据进行研究时,就通过统计学方法建立了相关预测模型^[9]。工程学方法建立预测模型通常被认为是较为准确和有效的,但实践中由于需要大量详细信息和参数的支撑,通常实现较为困难。统计学方法出现较早,理论和技术通常被认为更加成熟,但其普适性不够强,并且准确程度也很难达到较高的水平。近些年来,通过人工神经网络(Artificial Neural Network, ANN)建立预测模型的方法逐步完善,相比于传统方法的种种弊端,其模型的普适性较强,可与不同方法组合使用,且预测结果通常具有较高的准确性。国内外一些研究已经证实,神经网络预测模型在很多场景下有较为突出的表现^[10-12]。

图书馆建筑具有人员数目变化大,影响其能耗影响成因复杂,且不同因素的影响不同等特点。为了对高校图书馆建筑能耗进行相对简单且准确的预测,本文提出一种基于模糊聚类的相似日筛选和列文伯格-马夸尔特(Levenberg-Marquardt, LM)神经网络算法结合的能耗预测模型。同时,为了对模型的预测结果进行评价,引入三种评价指标。将本文所提模型与传统 LM 能耗预测模型进行比较,验证本文所提方法在预测结果准确性方面的优越性。

1 预测算法原理

1.1 相似日法

通常把多种特征,如日期、温度和湿度等,都近似的几日称之为相似日。由于状态的相似性,这些日期中产生的能耗通常更为趋同。利用这一特性,在能耗预测中使用相似日法可提高预测结果的准确性。

通常使用特征向量来对相似日进行描述。能耗预测中的特征向量一般由对能耗影响较为重要的因素构成。为选取此类因素,使用了数据分析法对能耗数据进行了研究。特征向量确定以后,再制定选取相似日的判断规则。在相似日选取结束后,将筛选出的数据导入预测模型,从而使模型的准确性提高^[13]。

以往使用相似日法时,由于相似日的界限通常较为模糊,选取过程往往依赖经验。但受制于人主观判断的影响,选取结果可能会存在较大的偏差。为了减少可能存在的结果偏差,同时又由于判断界限不分明原因,使用模糊聚类的方式

对相似日法中相似日的选取进行了改进。

1.2 模糊聚类

根据某些标准将特定事物的集合进行分类的过程被称为聚类分析^[13]。早期的聚类分析通常对判定界限有着明确的规定,这种聚类方法简单、快捷,非常适用于构成较为单一且事物界限分明的场景中。然而一旦需要处理界限不明确的复杂问题,传统聚类方法并不适用。在传统方法无法解决的复杂问题中,通常使用模糊聚类的方法。这种方法利用模糊数学的原理,将客观事物的关系通过其特征加以确定,并据此对其进行分类^[13-14]。

模糊聚类需要建立模糊矩阵:

样本集 $X = \{x_1, x_2, \dots, x_n\}$, 特征向量为 $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$ 。其中, n 表示样本数, m 为特征向量数。因此,样本集 X 的特征矩阵表示为

$$X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{pmatrix}$$

聚类过程中需要对相似度进行确定。相关的方法非常多,距离法就是最为常见的一种。距离法中包含的计算方式也多种多样,用于不同情境下的距离计算,如欧氏距离、夹角余弦等等都是较为常见的距离计算方法。其中欧氏距离计算简便,应用广泛,适用于本研究场景。此次使用此方法计算 $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$ 和 $x_j = (x_{j1}, x_{j2}, \dots, x_{jm})$ 之间的相似度 r_{ij} 。

$$r_{ij} = \sqrt{\sum_{k=1}^m (x_{ik} - x_{jk})^2} \quad (1)$$

样本集 X 的模糊矩阵为

$$\hat{R} = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1m} \\ r_{21} & r_{22} & \cdots & r_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nm} \end{pmatrix}$$

其中 $i, j = 1, 2, \dots, n$ 。

中间距离法是一种使用中间距离对类间距进行定位的方法,是系统聚类过程中的常用方法之一。相比于另外两种常见的类间聚类方法(最长距离法和最短距离法),这种方法可以既有保有相同的优势,又去掉了二者的缺陷。因此,在此次模糊聚类过程中使用此方法对类间距进行计算。

1.3 LM 算法原理

梯度下降法和高斯-牛顿法都是神经网络中的常用算法,而列文伯格-马夸尔特算法或称阻尼

最小算法^[15],是一种将二者进行结合的方法.这种结合算法同时具备两种方法的优势——全局特性和高效收敛.并且由于在解决各类非线性问题上具有优势^[16],其应用领域较广,涵盖经济、管理、设计等各个方面.

在传统前馈神经网络的基础上,使用LM算法代替梯度下降法寻求最优化问题的解,这种改进后的BP神经网络一般被称为LMBP神经网络或者简称LM神经网络^[7].

与BP神经网络相似,LM神经网络的训练过程也需要进行正向传播过程和反向传播过程.在正向传播过程中,两种神经网络的训练过程基本相同.而在第二步过程中,各层学习参数由LM算法经调整后得到.最终,误差收敛并稳定在合适区间后,停止训练^[17].LM算法对学习参数进行修正过程如下:

训练误差 ϵ 、系数 u_0 以及权重与阈值向量 $X^{(0)}$ 均已确定.

目标函数为平方误差函数,其公式如下.

$$E(x) = \frac{1}{2} \sum_{i=1}^N e_i^2(x) \quad (2)$$

式中: $e_i(x)$ 为第 i 个预测值和实际值的误差.

$$X^{(k)} = X^{(k-1)} + \Delta X^{(k-1)} \quad (3)$$

式中, $X^{(k)}$ 表示第 k 次循环的向量

ΔX 的公式为

$$\Delta X = -J(x)e(x)/[J^T(x)J(x) + uI] \quad (4)$$

式中, u 表示比例系数,且 $u > 0$, I 表示单位矩阵, $J(x)$ 表示雅可比矩阵

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_N} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \dots & \frac{\partial e_N(x)}{\partial x_N} \end{bmatrix} \quad (5)$$

当 $E(X^{(k)}) < \epsilon$ 时完成预测.否则,将权重与阈值向量更新为 $X^{(k+1)}$,计算误差函数 $E(X^{(k+1)})$.若 $E(X^{(k+1)}) < E(X^{(k)})$,则 $k = k + 1$, $u = u/\beta$,重新计算 $E(X^{(k+1)})$.反之,则 $X^{(k+1)} = X^k$, $u = u/\beta$,再次计算 ΔX 和 $E(X^{(k)})$.

2 实例分析

2.1 数据来源

实例建筑来源于西北某高校图书馆,其室内人员数据根据门禁系统记录计算得到,其能耗数

据来自高校内部的能耗监管平台,所使用的当地日均气温数据来自中国气象数据网.

图书馆的暑期时间表由2020年7月13日起实行至当年8月13日止,如表1所示.

表1 暑假图书馆开放时间表

Tab. 1 Library opening schedule during summer vacation

服务部位	开放时间
总服务台	周一、三、五 8:00—12:00
公共自习室	8:00—22:00

图书馆的学期开放时间表由2020年8月14日起开始实行,如表2所示.需要说明的是,在2020年10月1日至10月4日期间,由于节假日的缘故,除公共自习室于8:00—22:00开放外,其他区域关闭.

表2 学期图书馆开放时间表

Tab. 2 Library opening schedule during terms

服务部位	工作日	周末
公共自习室	7:00—23:00	
总服务台	8:00—22:00	
	8:00—12:00	8:30—12:00
	14:30—22:00	14:30—18:00
书库区	(夏季)	(夏季)
	14:00—22:00	14:00—18:00
	(冬季)	(冬季)
	8:00—12:00	
	14:30—18:30	
办公区	(夏季)	关闭
	14:00—18:00	
	(冬季)	

* (夏季)从5月1日到9月30日;(冬季)从10月1日到第二年4月30日.

考虑可用性数据和研究价值,选取2020年7月14日至2020年11月30日的共6700多条(包含能耗、气温和人数)数据进行研究.需要说明的是,能耗数据在2020年9月4日至7日出现记录缺失,但由于缺失的数据量很小,该缺失对整体研究结果造成的影响非常有限,因此,将其忽略.

2.2 数据分析

本研究对象为图书馆能耗,为确定其相似日特征向量及预测模型的输入参数,需要筛选出对该建筑物能耗影响较为重要的因素.因此,使用数据分析法对室内人员人数、日均气温与能耗数据进行了研究.

如图1所示,能耗存在三个高峰,包括两个夏季高峰和一个冬季高峰.如图2所示,夏季高峰期

间,日平均气温高,而冬季高峰期间,日均气温断崖式下跌.为维持室内温度适宜,空调系统耗能较大.由此可知,气温对图书馆建筑能耗产生的影响不可忽视.




图1 图书馆室内人数与能耗

Fig. 1 Occupancy and energy consumption




图2 图书馆室外日均气温

Fig. 2 Average daily outdoor temperature

能耗于7月12日后出现快速大幅下跌.此时图书馆由于暑假原因调整开放策略,只图书馆总服务台及自修室开放,其他服务区域等基本全部关闭.由此产生的大量照明系统及其他系统相关设备的关闭导致此时能耗下跌严重.而在8月14日进入学期开放状态后,图书馆建筑能耗逐渐回升.因此,图书馆开放策略的调整会影响图书馆能耗的变化.

拟合度((R-squared, R^2)可用来表示关系的线性程度,通常情况下,该值越接近1,则表示线性关系越明显.表3利用 R^2 对室内人员和能耗之间的关系进行了统计.从表3中可以发现,能耗的波动与室内人数的变化存在一定关系,但各月份 R^2 存在较大波动,即室内人员对能耗的影响程度在不同时期存在差别.结合前文对气温和开放策略对图书馆能耗的影响分析可推测,在某些月时期,气温或开放策略对能耗的影响超过了室内人员的

影响,而其他时期反之.根据实际数据, R^2 在7月下半月为0.6785,在9月下半月为0.912,在11月上半月为0.4412,均显著高于当月总体 R^2 ,且发生时间与气温或开放策略发生显著变化的时间大致吻合.由此可知,室内人数变化对该建筑能耗具有一定影响,但由于存在其他影响因素的相互作用,其影响程度会有所不同.

表3 图书馆室内人员与能耗的 R^2 统计表

Tab. 3 R-square value of the occupancy and the energy consumption in the library

	7月	8月	9月	10月	11月
R^2	0.0013	0.2603	0.1692	0.7675	0.1969

综上所述,室内人员人数、气温和图书馆开放策略都是对能耗影响较大的因素.

3 模型的建立

相似日LM神经网络预测模型的预测流程如图3所示.

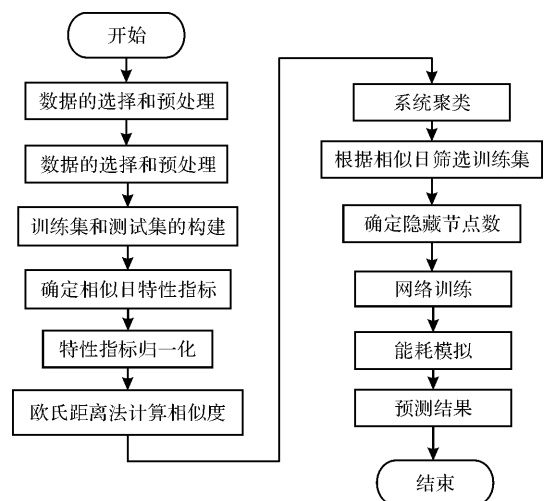


图3 预测流程

Fig. 3 Prediction process

3.1 输入和输出参数的选择

LM神经网络的结构通常是一层输入层、一至多层隐含层和一层输出层.其中,输入层和输出层的节点数由输入和输出的数据类型数决定.

根据2.2节数据分析,图书馆服务区域的逐时开放状况可作为一个参数进行输入.但由于开放状况无法直接以数字形式输入,因此,在进行模型构造前需要对其进行量化处理.将图书馆各区域分别进行参数设定,如表4所示.图书馆某时刻开放数据可由当时图书馆开放区域的参数累计得到,因此具体量化数据需参照表1与表2后获得.

气温也会影响图书馆能耗,但由于逐时气温

数据较难取得,所以使用日平均气温作为一个输入量。

表4 图书馆开放区域量化表

Tab. 4 Quantification table of library open areas

开放服务部位	参数
公共自修室	0.2
总服务台	0.2
书库区	0.2
办公区	0.4

由2.2节可知,室内人员数目的变化对建筑物能耗也具有影响。因此,将图书馆逐时室内人员数作为输入参数之一。

本研究主要针对图书馆建筑的能耗,因此输出参数为图书馆逐时能耗。

数据选择的时间范围从2020年7月13日到至2020年11月30日,剔除了个别缺失数据的部分。

综上所述,本研究中的输入层节点数为3,输出层节点数为1。

3.2 输入参数标准化与数据划分

由于输入参数之间存在数量级和单位的不一致,为了去除差异,常用的方法就是对参数进行归一化处理,公式如下所示。

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

式中: x 代表原始样本数据; y 为处理后的数据; x_{\max} 为样本数据最大值; x_{\min} 为样本数据最小值。

在模型构建中,需要设置训练集和测试集。因此,将归一化处理后的数据按照85%和15%的比例随机划分为两部分,分别作为训练集和测试集。

3.3 相似日选取

根据前文分析,已经得出相似日选取的特征向量,即图书馆开放策略 x_1 、气温 x_2 和室内人员 x_3 , 构建特征矩阵 $X = \{x_1, x_2, x_3\}$ 。下面对三个因素的量化进行说明。

首先是图书馆开放情况,其量化如表5所示。该表根据图1与图2的内容,对数值进行了设定。此处量化过程为简化数据处理过程,忽略了夏季与冬季图书馆开放情况的细微差异。这种差异在整体上看非常小,很难对结果造成较大影响,因此选择忽略。

另一个因素为气温,使用日平均气温数据描述当日的气温。

最后是室内人员情况。使用门禁系统记录的室内人员出入数据对日总室内人员数进行计算。

用日总室内人员数描述当日室内人员情况。

使用归一化处理消除特性指标间的数量级差异和量纲差异。

计算测试集与训练集的相似度,并对模糊相似矩阵进行聚类。使用系统聚类的方法将测试集对应的训练集分为相似日和非相似日。根据相似日从前一节划分的训练数据中筛选出相应数据作为模型真正的训练数据。

表5 图书馆开放时间量化

Tab. 5 Quantification table of library open hours

开放时期	参数
暑假周二、四、六、七	0
暑假周一、三、五	0.1
学期假期	0.5
学期工作日	1

3.4 隐含层参数设定

LM神经网络的隐含层层数和隐含层节点数不定。因此需要通过实验确定一个较为合适的数目。

由于本研究中的模型参数构成并不复杂,此类模型的隐含层层数的选取范围不应过大。因此,将其设定范围划定于1至3层。为选择最优设定值,对不同层数的模型进行实验,得到相应的迭代次数和均方误差(Mean Square Error, MSE)其实验结果如图4所示。为确保实验结果的可靠性,各模型的训练结果均为运行10次后的均值。

根据图4可知,使用2层隐含层与使用3层隐含层在迭代次数和准确性上表现较好。同时,考虑到模型的训练速度会随层数增加而下降,因此2层隐含层在此次模型中适用性更高。




图4 各隐含层层数迭代次数和均方误差

Fig. 4 The iterations and the MSE value of different hidden layers

隐含层节点数的范围一般可由经验公式获得。

$$y = \sqrt{x_{\text{in}} + x_{\text{out}}} + \alpha \quad (7)$$

式中: y 表示隐藏节点数; x_{in} 表示输入节点数;

x_{out} 表示输出节点数, $1 < \alpha < 10$.

输入参数数目为 3, 因此输入层节点数为 3, 输出参数为图书馆建筑的能耗, 故输出节点数应为 1. 由经验公式可得隐含层节点数范围为 3 至 12. 为确保结果可信度, 各相应模型均为 10 次训练后的均值, 其结果如图 5 所示. 由图 5 可知, 隐含层节点为 10 模型最优.




图 5 各隐含层节点数迭代次数和均方误差

Fig. 5 The iterations and the MSE value of different hidden layer nodes

4 结果验证

4.1 评价指标

为对能耗预测模型的性能进行评价, 使用三种常用的预测模型评价指标.

平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE), 其范围为 $[0, +\infty)$, MAPE 也大表示误差也越大, 其公式如下.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - R_i}{X_i} \right| \times 100\% \quad (8)$$

MSE 大于 0, 通常, 当 MSE 越接近 0 时, 模型越好, 其公式如下.

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - R_i)^2 \quad (9)$$

R^2 的范围为 $[0, 1]$, 一般情况下, R^2 越接近 1 时, 模型的拟合程度越好, 模型越完美.

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - R_i)^2}{\sum_{i=1}^n (\bar{X} - R_i)^2} \quad (10)$$

式中: n 为预测样本数; X_i 为第 i 个样本的真实能耗; R_i 为第 i 个样本的预测能耗.

4.2 结果对比

利用占数据总量 15% 的测试集对训练完成后的模型进行测试, 将两种预测结果指标进行对比, 如表 5 所示. 从各项评价指标的对比可知, 使用相似日法改进后, 模型的准确程度有较为明显的

提高.

表 6 模型预测结果评价指标对比

Tab. 6 Comparison of the two models' prediction indicators

评价指标	LM 模型	相似日 LM 模型
MAPE	12.09%	10.81%
MSE	42.93	19.87
R^2	0.910 4	0.952 5

为更清晰展示模型改进效果, 用 9 月 12 日的结果作为例子, 将两种模型的拟合度进行对比, 如图 6 和图 7 所示.




图 6 相似日 LM 神经网络模型拟合情况

Fig. 6 The comparison of the fitting value of the optimized LM model and the true value




图 7 普通 LM 神经网络模型拟合情况

Fig. 7 The comparison of the fitting value of the general LM model and the true value

从拟合程度对比可知, 普通 LM 神经网络预测结果中存在不少游离点, 整体预测精度下降; 而改进后的模型预测结果中, 基本没有偏差较大的游离点, 预测曲线的拟合程度明显更优.

综上可知, 使用相似日法进行改进的 LM 神经网络模型对于图书馆能耗的预测更加准确, 大偏差游离点基本消失, 预测曲线拟合程度更好.

5 结语

针对高校图书馆能耗问题, 使用 LM 神经网络模型进行预测, 并使用相似日法改进模型. 该

相似日方法使用模糊聚类进行相似日选取.通过和普通LM神经网络预测模型结果的实验对比,证明改进后的预测模型可以更准确地对高校图书馆的能耗进行预测.更准确的预测模型不仅可为日后建筑综合能耗系统的研究提供有力的基础,同时也有利于节能策略研究工作的进一步发展.

本次研究主要聚焦于预测模型的改进,因此使用的能耗数据并未细化分类.若进一步针对不同区域及不同系统的特征,建立更加细致的模型,可对相关模型的适用性进行更多研究.

参考文献 References

- [1] 谭洪卫,徐钰琳,胡承益,等.全球气候变化应对与我国高校校园建筑节能监管[J].建筑热能通风空调,2010,29(1):36-40.
TAN Hongwei, XU Yulin, HU Chengyi, et al. Research on building campus energy management[J]. Building Energy & Environment, 2010,29(1):36-40.
- [2] YAN Ding, WANG Qiaochu, WANG Zhaoxia, et al. An occupancy-based model for building electricity consumption prediction: A case study of three campus buildings in Tianjin[J]. Energy & Buildings, 2019, 202:109412.
- [3] 高彪,谭洪卫,宋亚超.高校校园建筑用能现状及存在问题分析——以长三角地区某综合型大学为例[J].建筑节能,2011,39(2):41-44.
GAO Biao, TAN Hongwei, SONG Yachao. Campus building energy consumption: Taking one comprehensive university as example[J]. Building Energy Efficiency, 2011,39(2):41-44.
- [4] CHUNG Min Hee, RHEE Eon Ku. Potential opportunities for energy conservation in existing buildings on university campus: A field survey in Korea[J]. Energy & Buildings, 2014,78: 176-182.
- [5] WALTER Leal Filho, AMANDA Lange Salvia, AR-MINDA do Paço, et al. A comparative study of approaches towards energy efficiency and renewable energy use at higher education institutions[J]. Journal of Cleaner Production, 2019,237:117728.
- [6] WANG Y, SHAO L. Understanding occupancy pattern and improving building energy efficiency through Wi-Fi based indoor positioning[J]. Building and Environment, 2017, 45(3): 53.
- [7] 王茜.西北某高校图书馆能耗预测模型与节能策略研究[D].西安:西安建筑科技大学,2021.
WANG Qian. Energy consumption prediction model and energy saving strategy research of a university library in northwest China[D]. Xi'an: Xi'an Univ. of Arch. & Tech., 2021.
- [8] YIK F W H, Burnett J, Prescott I. Predicting air-conditioning energy consumption of a group of buildings using different heat rejection methods[J]. Energy & Buildings, 2001,33(2): 151-166.
- [9] SEPEHR M, EGHTEDAEI R, TOOLABIMOGH-ADAM A, et al. Modeling the electrical energy consumption profile for residential buildings in Iran[J]. Sustainable Cities and Society, 2018, 41(10): 481-489.
- [10] MERIH Aydinalp, V. ISMET Ugursal, ALAN S. Fung. Modeling of the appliance, lighting, and space-cooling energy consumptions in the residential sector using neural networks[J]. Applied Energy, 2002,71(2): 87-110.
- [11] ALBERTO Hernandez Neto, FLÁVIO Augusto Sanzovo Fiorelli. Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption[J]. Energy & Buildings, 2008,40(12): 2169-2176.
- [12] LI Q, REN P, MENG Q. Prediction model of annual energy consumption of residential buildings[C]//2010 International Conference on Advances in Energy Engineering. Beijing:ICAEE, 2010.
- [13] 谈力.基于相似日选取的小波极限学习机短期负荷预测模型研究[D].南京:南京理工大学,2015.
TAN Li. Short-term power load forecasting based on similar days and extreme learning machine[D]. Nanjing: Nanjing University of Science & Technology, 2015.
- [14] 张悦.某大型公共建筑能耗分形特性与预测模型研究[D].西安:西安建筑科技大学,2019.
ZHANG Yue. Studies on fractal characteristics and forecasting model of energy consumption of a large public building[D]. Xi'an: Xi'an Univ. of Arch. & Tech., 2019.
- [15] 黄豪彩,黄宜坚,杨冠鲁.基于LM算法的神经网络系统辨识[J].组合机床与自动化加工技术,2003(2): 6-8.
HUANG Haocai, HUANG Yijian, YANG Guanlu. Neural network system identification based on levenberg-marquardt algorithm[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2003(2): 6-8.
- [16] QIAO J, WANG L, YANG C, et al. Adaptive levenbergmarquardt algorithm based echo state network for chaotic time series prediction[J]. IEEE Access, 2018, 6:10720-10732.
- [17] 杨雪.基于深度学习的大型公建能耗预测及信息管理系统研究[D].西安:西安建筑科技大学,2019.
YANG Xue. Study on energy consumption prediction and information management system based on deep learning for large-scale public building[D]. Xi'an: Xi'an Univ. of Arch. & Tech., 2019.

(编辑 吴海西 沈波)