

基于 DeST 仿真和 GS-SVR 算法对严寒气候区近零能耗公共建筑逐时负荷预测

冯国会,李奇岩,王 刚,李环宇

(沈阳建筑大学市政与环境工程学院,辽宁 沈阳 110168)

摘 要 目的 为使空调系统能够及时对近零能耗建筑室内负荷变化做出反应,提出基于 DeST 仿真与支持向量机回归算法(SVR)的预测方法。方法 以位于沈阳建筑大学校内的近零能耗示范建筑为例,通过 DeST 仿真得到模型需要的原始数据,利用网格搜索算法(GS)对支持向量机算法中的参数进行优化,采取优化后的支持向量机回归算法(GS-SVR)对负荷数据进行训练与预测。结果 GS-SVR 预测模型的 $MSE_{\text{供热}}$ 与普通 SVR 预测模型相比降低了 13.61%, R^2 提高了 1.25%; $MSE_{\text{供冷}}$ 与普通 SVR 预测模型相比降低了 2.49%, R^2 提高了 1.36%。结论 GS-SVR 算法提高了严寒地区近零能耗建筑室内负荷预测的精确度,可对近零能耗建筑的空调系统运行诊断及优化。

关键词 支持向量机;网格搜索;DeST 仿真模拟;近零能耗建筑;严寒气候区

中图分类号 TU111.195

文献标志码 A

Hourly Load Forecast of nZEB in Severe Cold Area Based on DeST Simulation and GS-SVR Algorithm

FENG Guohui, LI Qiyan, WANG Gang, LI Huanyu

(School of Municipal and Environmental Engineering, Shenyang Jianzhu University, Shenyang, China, 110168)

Abstract: In order to enable the air conditioning system to respond to load changes of a nearly zero energy building (nZEB) in time, a prediction method based on DeST simulation and Support Vector Regression (SVR) was studied. A nearly zero energy demonstration building in Shenyang Jianzhu University was selected as an example. First, DeST simulation was used to obtain the original data, and then parameters in SVR algorithm was optimized by the grid search (GS) algorithm. Last, heating and cooling loads of nZEB was trained and predicted by GS-SVR model. The results show that MSE_{heating} of the GS-SVR prediction model is reduced by 13.61% compared with SVR prediction model, and R^2_{heating} is increased by 1.25%; however, MSE_{cooling} is reduced by

收稿日期:2021-04-13

基金项目:国家自然科学基金项目(51778376);"十三五"国家重点研发计划项目(2017YFC0702600)

作者简介:冯国会(1964—),男,教授,博士研究生导师,主要从事可持续绿色生态建筑技术方面研究。

2.49%, and $R^2_{cooling}$ is increased by 1.36%. So the accuracy of indoor load prediction for nZEBs in severe cold area is improved by GS-SVR algorithm, and a reference for operating diagnosis and optimization of air-conditioning systems in nZEBs is provided by the algorithm.

Key words: support vector machine; grid search; DeST simulation; nZEB; severe cold climate zone

目前我国存在大量的既有公共建筑,空调系统占建筑总运行能耗的 30% ~ 40%^[1]。在空调的使用中,由于温度传感器无法全面地获取室内的温度信息,使得其送风温度或送风量等过大或过小,甚至出现系统信号变化的延迟,导致空调系统向室内供给的负荷量与建筑需要的负荷量不能很好地匹配。因此通过对相关参数的测量,空调系统能够对室内负荷进行预测,提前调节空调送风量与温湿度,从而使空调系统的送风参数达到要求,以此避免能源浪费。目前的建筑预测模型主要有以热力学方程为基础的物理模型^[2]和以机器学习为基础的数据模型^[3-9]。相比于物理模型,数据模型具有计算速度快,使用简便等优势。当前使用的机器学习算法主要有支持向量机(SVM)、人工神经网络(ANN)^[3]、组合学习(Ensemble Learning)^[10]、深度学习(DP)^[11]等。支持向量机算法使用正则化项来避免数据的过拟合,算法中的核技巧也有助于处理非线性数据^[12],因此成为目前流行的预测算法之一。H. Zhong 等^[13]提出了一种新的基于向量场的支持向量回归方法找到最优特征空间。F. Zhang 等^[14]使用差分进化算法为 nu-SVR 和 epsilon-SVR 分配权重,从而提高其预测精度。这些方法都对算法本身进行修改以达到更好地预测精度。但现今使用的支持向量机算法大部分被封装在相应的算法库中,例如 scikit-learn 算法包中封装了包括支持向量机等大部分机器学习算法^[15],在实际操作中直接调用算法包中的相关算法即可实现较高的预测精度。机器学习中数据的来源将直接影响到训练结果的好坏。目前在国外有 67% 的研究使用真实的建筑运行数据进行模

型训练,19% 的研究使用模拟数据进行模型训练^[16]。由于国内的近零能耗公共建筑能耗监测工作起步较晚,相关数据库建立并不完善。因此笔者使用 DeST 软件的模拟数据进行模型训练与预测,并使用支持向量机回归算法(SVR)时将调用 scikit-learn 中的相关模块,并使用网格搜索算法(GS)对超参数进行组合寻优。

1 方法及原理

1.1 支持向量机回归

支持向量机是一种二分类模型,基本模型是定义在特征空间上的间隔最大的线性分类器,可以将输入向量映射为特征空间中的特征向量^[17],从而解决在原始输入空间中无法线性可分的问题。该算法的分离超平面为

$$\mathbf{w}^* \cdot \mathbf{x} + b^* = 0.$$
 (1)

相应的分类决策函数为

$$f(\mathbf{x}) = \text{sign}(\mathbf{w}^* \cdot \mathbf{x} + b^*).$$
 (2)

式中: \mathbf{w}^* 超平面的法向量; \mathbf{x} 为输入变量; b^* 为超平面的截距。

对于线性不可分的训练数据,可以修改硬间隔最大化^[17],使其成为软间隔最大化。并对原始问题的对偶问题进行求解:

$$\min \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N a_i. \quad (3)$$

$$\text{s. t. } \begin{cases} \sum_{i=1}^N a_i y_i = 0, \\ 0 \leq a_i \leq C, i = 1, 2, \dots, N. \end{cases} \quad (4)$$

式中: $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 为训练数据集; $\mathbf{a} = (a_1, a_2, \dots, a_N)^T$ 为拉格朗日乘子向量。

在输入空间的维度过高时,内积计算($x_i \cdot x_j$)会耗费大量计算机资源,因此引入核

技巧^[18]来避免此类现象发生。在支持向量机中可以使用核函数代替内积计算。常用的核函数包括 poly 核函数、RBF 核函数等。由于核函数中存在需要手动调节的参数(超参数),因此核函数的选择以及核函数中的超参数对模型性能好坏有直接影响。Drucker Harris 等^[19]将该算法扩展到支持向量回归。

1.2 网格搜索算法

网格搜索本质上是一种穷举法。其主要思想为,在指定的参数组合范围内,按步长依此调整参数,利用调整的参数训练学习器,从所有的参数中找到在精度最高的参数。但穷举法的时间复杂度为 $\theta(n^m)$,其中 n 为输入变量个数; m 为每个输入变量的取值。同时使用该算法表示的参数组合过于稀疏,浪费计算机的内存空间。因此 Bao Yukun 等^[20]提出在模型训练中寻找最大误差下降路径,以此优化网格搜索路径;J. Bergstra 等^[21]提出当超参数规模较大时,随机搜索将会是更高效的超参数优化方法。

1.3 训练效果指标

笔者主要使用均方误差 MSE 和决定系数 R^2 作为评价训练结果的指标。均方误差能够体现预测值与真实值之间的离散程度,而决定系数 R^2 反应因变量的全部变异性能通过回归关系被自变量解释的比例。两个指标分别为

$$MSE(y,\hat{y}) = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 . \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2 / m}{\sum_{i=1}^m (y_i - \bar{y})^2 / m} . \quad (6)$$

式中: y_i 为实际观测值; \hat{y}_i 为支持向量机模型的预测值; \bar{y} 为实际观测值的平均值。

2 建筑负荷数据获取

2.1 建筑基础信息

选取位于沈阳建筑大学校区内的近零能耗示范建筑^[22](见图 1)作为研究对象。该建

筑处于严寒气候 1C 区,建筑面积为302.4 m²,体形系数 0.54,共两层,无地下室。第 1 层高 3.3 m,为住宅示范,房间功能为卧室、厨房、设备间、控制室、展厅以及卫生间。第 2 层高为 3.6 m,房间功能分为开场办公区、封闭办公室以及卫生间,主要用来做科研办公。该建筑的围护结构参数如表 1 所示。



图 1 近零能耗示范建筑外观图

Fig. 1 Picture of the nearly zero energy demonstration building

表 1 近零能耗示范建筑围护结构参数

Table 1 Envelope parameters of the nearly zero energy demonstration building

围护结构名称	传热系数/(W·(m ² ·K) ⁻¹)
外墙	0.099
屋面	0.090
地面	0.113
窗体传热系数	1.000

2.2 建筑负荷计算结果

以该建筑的 CAD 图纸为参照在 DeST 软件中建立模型,内扰按照《近零能耗建筑技术标准》(GB/T51350—2019)进行设定,由此得到全年逐时空调负荷分布(见图 2)。由图可知,近零能耗建筑的负荷变化具有季节性,可概括为供热季与供冷季。该建筑作为办公建筑使用,因此日负荷变化也具有周期性,与办公人员的作息规律相似。其中全年累计单位面积热负荷为30.56(kW·h)/m²,全年累计单位面积冷负荷为 39.22(kW·h)/m²。




图2 近零能耗示范建筑全年逐时空调负荷

Fig.2 Hourly loads of the nearly-zero energy demonstration building

3 基于支持向量机算法的负荷预测模型建立

3.1 数据预处理

将数据集分为供热季与供冷季两部分。供热季从11月1日到次年3月15日,供冷季从7月1日到9月15日。过渡季依靠自然通风换热,空调处于关闭状态,无需计算该时间段冷、热负荷。基础建筑的负荷情况如表2所示。

为了消除不同变量间的量纲影响,需要在模型训练前对数据进行归一化。数据归一化将数据按比例缩放,使之映射到一个特定

表2 近零能耗示范建筑的负荷模拟结果

Table 2 Load simulation results of the nearly zero energy demonstration building

总空调 面积/m ²	全年累计热 负荷/(kW·h)	全年累计冷 负荷/(kW·h)	全年累计单位 面积热负荷/ (kW·h)·m ⁻²	全年累计单位 面积冷负荷/ (kW·h)·m ⁻²	供热季单位 面积热负荷/ (W·m ⁻²)	供冷季单位 面积冷负荷/ (W·m ⁻²)
302.40	9 241.54	11 859.85	30.56	39.22	8.28	13.81

区间。由于原始数据中以正数表示热负荷,负数表示冷负荷,因此在本研究中原始数据被映射到[-1,1]区间,而输出值则需要逆向缩放得到预测值。

3.2 模型输入变量选取

选取室外气象参数(干球温度、含湿量、总辐射、散射辐射、直射辐射),相应时刻,1 h

前负荷值与24 h前负荷值为模型的输入变量。鉴于建筑负荷与其影响因素之间的非线性特性,笔者使用单变量模型拟合训练集数据,得到各变量对室内负荷的影响程度。其中SVR模型使用默认的超参数,并使用R²值作为性能指标。单变量模型拟合结果如表3所示。

表3 单变量模型拟合结果

Table 3 Results of univariate model test

负荷季	R ²							
	相应 时刻	干球 温度	含湿量	总辐射	散射 辐射	直射 辐射	1 h 前 负荷	24 h 前 负荷
供热季	0.012 05	-0.032 47	0.012 53	-0.104 20	-0.117 06	-0.115 65	0.651 81	0.795 57
供冷季	0.012 82	0.685 21	0.212 20	0.302 65	0.258 92	0.070 09	0.798 67	0.726 19

由表3可知,供冷季中R²值皆为正数,说明选取的每个参数都能在一定程度上反应室内冷负荷的变化,因此在冷负荷预测模型中选取干球温度、含湿量、总辐射、散射辐射、直射辐射、相应时刻、1 h前负荷值与24 h前

负荷值作为冷负荷预测模型的输入参数。而在热负荷预测模型的单变量拟合结果中,干球温度、总辐射、散射辐射和直射辐射的R²值为负数。为进一步探究这4个变量与室内热负荷的相关性,笔者使用除去相应的单变

量以外的变量作为模型的输入参数,再一次对训练集进行拟合,得到的 R^2 值如表 4 所示。去除干球温度后热负荷模型 R^2 值为 0.919 61,与去除其他单变量以后的模型 R^2 值差距较大。这说明去除干球温度后的热负荷预测模型的准确度降低程度较大,该变量对热负荷的影响较大。因此将干球温度作为输入参数。

表 4 除去相应变量以后模型 R^2 值

Table 4 R^2 after removing the corresponding variables

负荷季	R^2			
	干球温度	总辐射	散射辐射	直射辐射
供热季	0.919 61	0.932 41	0.931 20	0.934 16

3.3 核函数选择以及超参数优化

仅改变核函数类型,将模型中其他参数保持默认设置,不同核函数下模型的拟合性能如表 5 所示。笔者使用的核函数分别为 linear 核函数、poly 核函数和 RBF 核函数。经对比发现,在使用 MSE 为考察指标时,选取 RBF 核函数时模型拟合性能最好,分别为 $MSE_{\text{供热}} = 0.093\ 20$ 和 $MSE_{\text{供冷}} = 0.056\ 57$;选取 ploy 核函数时模型拟合性能最差,分别为 $MSE_{\text{供热}} = 0.162\ 26$ 和 $MSE_{\text{供冷}} = 0.241\ 97$ 。在使用 R^2 为考察指标时,选取 RBF 核函数时模型拟合性能最好,分别为 $R^2_{\text{供热}} = 0.906\ 39$

和 $R^2_{\text{供冷}} = 0.942\ 86$;选取 poly 核函数时模型拟合性能最差,分别为 $R^2_{\text{供热}} = 0.838\ 06$ 和 $R^2_{\text{供冷}} = 0.753\ 42$ 。因此,笔者选用 RBF 核函数作为支持向量机回归的核函数。

表 5 不同核函数下模型的拟合性能

Table 5 Performance of models under different kernel functions

核函数类型	负荷季	拟合性能	
		MSE	R^2
linear	供热季	0.142 98	0.855 37
	供冷季	0.123 70	0.874 22
poly	供热季	0.162 26	0.838 06
	供冷季	0.241 97	0.753 42
RBF	供热季	0.093 20	0.906 39
	供冷季	0.056 57	0.942 86

使用网格搜索对 RBF 核函数中的 $gamma$ 参数和表示惩罚程度的 C 参数进行组合寻优。其中参数 $gamma$ 的范围为 $[0.1, 10]$,参数 C 的范围为 $[10, 100]$ 。交叉验证设置为 10 次 10 折验证,并使用 10 次结果的算数平均值作为最终结果。寻优结果显示:当 $gamma$ 参数取 0.1, C 参数取 11 时,训练集上的 $MSE_{\text{供热}}$ 降低了 8.49%, $R^2_{\text{供热}}$ 提高了 8.50%; $MSE_{\text{供冷}}$ 降低了 6.09%, $R^2_{\text{供冷}}$ 提高了 4.07%。优化前后的结果如表 6 所示。

表 6 使用网格搜索优化前后模型的超参数与拟合性能

Table 6 Hyperparameters and performance of the SVR model and the GS-SVR model

模型	负荷季	训练集		测试集		超参数		
		MSE	R^2	MSE	R^2	核函数	C	$gamma$
SVR	供热季	0.093 18	0.906 41	0.767 52	0.915 67	RBF	1	0.1
	供冷季	0.056 63	0.942 79	1.289 25	0.948 30	RBF	1	0.1
GS-SVR	供热季	0.085 26	0.914 12	0.663 06	0.927 15	RBF	11	0.1
	供冷季	0.053 18	0.946 63	1.257 13	0.949 59	RBF	11	0.1

分别计算 SVR 模型与 GS-SVR 模型在测试集上的表现。结果显示,对于供热季, MSE 从原来的 0.767 52 变为 0.663 06,比优化前降低了 13.61%; R^2 从原来的 0.915 67 变为 0.927 15,比优化前提高了 1.25%。对

于供冷季, MSE 从原来的 1.289 25 变为 1.257 13,比优化前降低了 2.49%。 R^2 从原来的 0.948 30 变为 0.949 59,比优化前提高了 1.36%。由此说明,在训练集和测试集上,网格搜索算法都能够提高支持向量机回

归算法的精确度。

4 模型预测结果

GS-SVR 模型的拟合度 R^2 与离散程度 MSE 均在表 6 中列出。无论是供热季还是供冷季,测试集的拟合度 R^2 相较于训练集的 R^2 都有所提升,说明 GS-SVR 模型能够很好地解释输入参数与结果之间的回归关系。而测试集上的 $MSE_{供冷}$ 远大于 $MSE_{供热}$,说明 GS-SVR 模型对冷负荷预测的精确度要低于对热负荷预测的精确度。原因在于夏季影响室内冷负荷的因素众多,而且冷负荷的变化较为剧烈,导致 GS-SVR 模型对室内冷负荷的预测更加困难。

为进一步说明网格搜索算法对支持向量机回归算法的提升作用以及 GS-SVR 模型在不同季节中精确度的差异,笔者究对供热季 1 月 1 日与供冷季 7 月 1 日的室内负荷进行预测,并将预测值与 DeST 软件模拟值进行对比(见图 3)。从图中可看出,在空调系统使用期间,GS-SVR 的预测值比支持向量机的预测值更加靠近模拟值,同时冷负荷预测值与真实值的偏离程度要大于热负荷预测值与真实值的偏离程度。由此说明,GS-SVR 模型相比于 SVR 模型精确度更高,而 GS-SVR 模型在供冷季期间的精确度要低于供热季。





图3 负荷预测结果

Fig.3 Prediction results of loads

5 结论

(1)选取干球温度、含湿量、总辐射、散射辐射、直射辐射、相应时刻、1 h 前负荷值与 24 h 前负荷值作为冷负荷预测模型的输入参数,并且将干球温度、含湿量、相应时刻、1 h 前负荷值与 24 h 前负荷值作为热负荷预测模型的输入参数。

(2)GS-SVR 热负荷预测模型的 MSE 与普通 SVR 模型相比降低了 13.61%, R^2 提高了 1.25%;冷负荷预测模型的 MSE 与普通 SVR 模型相比降低了 2.49%, R^2 提高了 1.36%。GS-SVR 模型的预测精度有了较大

提升,也能够更好地解释输入参数与结果之间的回归关系。

(3)测试集上 $MSE_{供冷}$ 值为 1.257 13, $MSE_{供热}$ 值为 0.663 06, $MSE_{供冷}$ 值远大于 $MSE_{供热}$ 值。GS-SVR 模型对热负荷的预测更加精确。原因在于供冷季影响冷负荷的因素较多,同时冷负荷的变化也较为剧烈。

参考文献

[1] 孙洪鹏,陈晨,张广智. 国内大型公共建筑空调系统运行管理现状调查研究[J]. 建筑节能,2020,48(10):8-13.
(SUN Hongpeng, CHEN Chen, ZHANG Guangzhi. Investigation on the operation and management of air-conditioning system for large public buildings in China [J]. Building energy

- efficiency, 2020, 48(10): 8-13)
- [2] DAHANAYAKE K, CHOW C. Studying the potential of energy saving through vertical greenery systems; using energy plus simulation program [J]. *Energy & buildings*, 2017, 138: 47-59.
 - [3] AHMAD T, CHEN H X, GUO Y B, et al. A comprehensive overview on the data driven and large scale based approaches for forecasting of building energy demand; a review [J]. *Energy & buildings*, 2018, 165: 301-320.
 - [4] 张宇帆, 艾芊, 林琳, 等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. *电网技术*, 2019, 43(6): 1884-1892.
(ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level [J]. *Power system technology*, 2019, 43(6): 1884-1892.)
 - [5] 那幸仪, 贾俊铨, 赵晓筠, 等. 基于小波变换和 LSTM 模型的城市天然气负荷预测[J]. *计算机应用与软件*, 2021, 38(12): 61-66.
(NA Xingyi, JIA Juncheng, ZHAO Xiaojun, et al. City natural gas load forecasting based on wavelet transform and LSTM model [J]. *Computer applications and software*, 2021, 38(12): 61-66.)
 - [6] 王洪亮, 陈新源, 赵雨梦. 基于集合经验模态分解和 ARIMA-GRNN 的负荷预测方法[J]. *电子科技*, 2021, 34(12): 42-48.
(WANG Hongliang, CHEN Xinyuan, ZHAO Yumeng. Load forecasting method based on ensemble empirical mode decomposition and ARIMA-GRNN [J]. *Electronic science and technology*, 2021, 34(12): 42-48.)
 - [7] 张栋栋, 陈洁, 李洋. 基于 VMD-SE 和 BiLSTM 在短期负荷预测应用[J]. *现代电子技术*, 2021, 44(23): 155-159.
(ZHANG Dongdong, CHEN Jie, LI Yang. Application of VMD-SE and BiLSTM in short-term load forecasting [J]. *Modern electronics technique*, 2021, 44(23): 155-159.)
 - [8] 徐嘉杰, 卢兆军, 袁飞, 等. 基于深度神经网络和 SoftMax 分类器的台区负荷分类识别方法[J]. *电气自动化*, 2021, 43(6): 102-104.
(XU Jiajie, LU Zhaojun, YUAN Fei, et al. Classification and identification method of station load based on deep neural network and Soft Max classifier [J]. *Measurement and detecting technics*, 2021, 43(6): 102-104.)
 - [9] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. *电力系统保护与控制*, 2020, 48(21): 117-124.
(LI Yan, JIA Yajun, LI Lei, et al. Short term power load forecasting based on a stochastic forest algorithm [J]. *Power system protection and control*, 2020, 48(21): 117-124.)
 - [10] WANG Z Y, WANG Y R, SRINIVASAN R. A novel ensemble learning approach to support building energy use prediction [J]. *Energy & buildings*, 2018, 159: 109-122.
 - [11] MOCANU E, NGUYEN P, GIBESCU M, et al. Deep learning for estimating building energy consumption [J]. *Sustainable energy, grids and networks*, 2016, 6: 91-99.
 - [12] DONG B, CAO C, LEE S E. Applying support vector machines to predict building energy consumption in tropical region [J]. *Energy & buildings*, 2005, 37(5): 545-553.
 - [13] ZHONG H, WANG J J, JIA H J, et al. Vector field-based support vector regression for building energy consumption prediction [J]. *Applied energy*, 2019, 242: 403-414.
 - [14] ZHANG F, DEB C, LEE S E, et al. Time series forecasting for building energy consumption using weighted support vector regression with differential evolution optimization technique [J]. *Energy & buildings*, 2016, 126: 94-103.
 - [15] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: machine learning in python [J]. *The journal of machine learning research*, 2011, 12: 2825-2830.
 - [16] AMASYALI K, EL-GOHARY N. A review of data-driven building energy consumption prediction studies [J]. *Renewable and sustainable energy reviews*, 2018, 81: 1192-1205.
 - [17] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine learning*, 1995, 20: 273-297.
 - [18] BOSER B, GUYON I, VAPNIK V. A training algorithm for optimal margin classifiers [C]. *Proceedings of the fifth annual workshop on computational learning theory*. Pittsburgh, Pennsylvania, USA. Association for computing machinery, 1992.
 - [19] DRUCKER H, BURGESS C, KAUFMAN L, et al. Support vector regression machines [C]. *Proceedings of the 9th international conference on neural information processing systems*. Cambridge, MA, USA. MIT press, 1997.
 - [20] BAO Y K, LIU Z T. A fast grid search method in support vector regression forecasting time series [C]. *Intelligent data engineering and automated learning*. Berlin, Heidelberg. Springer berlin heidelberg, 2006.
 - [21] BERGSTRÄ J, BENGIO Y. Random search for hyper-parameter optimization [J]. *Journal of machine learning research*, 2012, 13(10): 281-305.
 - [22] 冯国会, 徐小龙, 王悦, 等. 以能耗为导向的近零能耗建筑围护结构设计参数敏感性分析[J]. *沈阳建筑大学学报(自然科学版)*, 2018, 34(6): 1069-1077.
(FENG Guohui, XU Xiaolong, WANG Yue, et al. Sensitivity analysis of nearly zero energy buildings envelope design parameters based on energy consumption [J]. *Journal of Shenyang jianzhu university (natural science)*, 2018, 34(6): 1069-1077)

(责任编辑:徐玉梅 英文审校:唐玉兰)