

doi:10.11835/j.issn.1000.582X.2023.12.007

基于 VMD-GRU 网络大型公共建筑冷负荷预测

于军琪,解云飞,赵安军,王佳丽,冉彤,惠蕾蕾

(西安建筑科技大学 建筑设备科学与工程学院,西安 710055)

摘要:基于冷负荷时间序列固有的复杂性和不规则性,针对预测过程中容易出现梯度消失、模态混叠和过拟合等问题,提出一种集成变分模态分解(variational mode decomposition,VMD)和门控循环单元网络(gated recurrent unit,GRU)的 VMD-GRU 模型。对原始数据进行相关性分析,挑选出相关性高的进行预测;使用 VMD 将原始数据序列分解为独立固有模式函数;使用 GRU 对每个分量进行预测;将分量预测结果相加得出冷负荷预测值。为验证模型的有效性,以西安某大型公共建筑为例进行能耗分析,并与 BP、GRU、EMD-BP、VMD-BP、EMD-GRU 等其他预测模型进行对比。实验结果表明,提出的 VMD-GRU 模型可有效解决梯度消失、模态混叠和过拟合等问题,预测精度显著提高,预测效果优于其它预测模型,符合大型公共建筑冷负荷的变化规律,为节能优化提供有力数据支撑。

关键词:大型公共建筑;预测算法;相关性分析;变分模态分解

中图分类号:TU831

文献标志码:A

文章编号:1000-582X(2023)12-066-14

Research on cold load forecasting model of large public buildings based on VMD-GRU network cold load forecasting model of large public buildings based on VMD-GRU network

YU Junqi, XIE Yunfei, ZHAO Anjun, WANG Jiali, RAN Tong, HUI Leilei

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

Abstract: Due to the inherent complexity and irregularity of cold load time series data, problems such as gradient disappearance, modal aliasing and over-fitting are prone to occur during the prediction process. Predicting the cold load of large public buildings remains a challenging task. To solve this problem and improve the prediction accuracy, the VMD-GRU model is proposed in this study. Real data from large public buildings were utilized to test the proposed model. The prediction process involves the following steps: 1) Correlation analysis of the original data and selection of highly correlated predictors; 2) Decomposition of the original data sequence into independent eigenmode functions using VMD; 3) Prediction of each component using GRU; 4) Aggregation of component prediction results to obtain the cold load prediction value. To validate the model's effectiveness, a large

收稿日期:2020-07-13

基金项目:陕西省重点研发计划资助项目(Z20180244);碑林区应用技术研发资助项目(GX1903)。

Supported by Shaanxi Province Key Research and Development Plan Project (Z20180244), Beilin District Applied Technology Research and Development Project (GX1903).

作者简介:于军琪(1969-),男,教授,博士生导师,主要从事智能建筑方向研究。

通信作者:赵安军,男,副教授,硕士生导师,(E-mail)zhao_anjun@163.com。

public building in Xi'an is taken as an example for energy consumption analysis. The results are compared with other prediction models, including BP, GRU, EMD-BP, VMD-BP, EMD-GRU. Experimental results show that the proposed model effectively solves the problems, such as gradient disappearance, modal aliasing and over-fitting, accurately predicting the cold load of large public buildings.

Keywords: large public buildings; prediction algorithm; correlation analysis; variational modal decomposition

全球能源消耗量伴随经济发展迅速增长,其中建筑能耗占比高达 40%^[1]。大型公共建筑由于舒适度要求高、人流量大、空调系统运行时间长等特点,成为建筑能耗中的“巨无霸”,对其能耗进行准确可靠预测成为关注热点。

建筑能耗受多种因素影响,例如气候状况、室内条件和人员流动^[2]。提高预测精度就需把握建筑冷负荷的变化规律:随机性、周期性、非线性和非平稳性。解决建筑能耗预测有许多优化模型,大体分为三类:物理学模型、数据驱动模型和混合模型^[3]。基于物理模型(也称白盒模型)的常用模拟软件有 EnergyPlus, eQuest 和 Ecotect。Foucquier 和 Yildiz 等人^[4]创建“热模型”进行校园能耗预测。使用物理学模型模拟建筑能耗模型(BEM)需要在利用物理方程式的基础上收集详细建筑信息,复杂度较高,不能广泛应用。虽然 Fumo 应用“工程方法”实现了对物理模型校准^[5],但随动性差,实时性不强;数据驱动模型(也被称为黑盒模型)根据历史数据进行统计分析和机器学习,具有较好学习能力和泛化能力而被广泛应用。钱志^[6]使用改进型人工鱼群和 SVR 混合模型对需求侧负荷进行预测,但当输入数据过多时,精度和收敛速度明显降低。李军在能耗预测时依靠经验获取 SOM 神经网络的隐层节点数和训练次数^[7]。混合模型(也称为灰盒模型)是物理模型和数据驱动模型相结合的方法^[8-11]。多种组合的方法和单一的人工智能方法比较,组合后的方法性能优于单一的传统方法,适用于多种类型的建筑^[12-13]。王林^[14]使用 FOA 优化 ESN 算法建立电力需求与多种因素之间的非线性关系对工业用电量(IEC)进行预测,虽然 FOA 算法可以对 ESN 的 4 个关键初始参数进行优化,但易陷入局部最优,并且它的搜索路径太粗糙。雷建文^[15]提出灰色关联分析和蝙蝠优化神经网络的预测模型对短期负荷进行预测,但是灰色模型对非平稳变化序列难以辨识,预测值与实际值存在较大误差,成为提高预测模型精度的瓶颈。

有学者将经验模式分解(empirical mode decomposition, EMD)应用于预测领域并取得初步成效^[16],然而该技术却存在局限性,易出现模态混叠现象,造成失真,影响负荷预测精度。为避免发生模态混叠现象,降低原始负荷序列的复杂度和非线性。Dragomiretskiy 和 Zosso^[17]在 2014 年提出非平稳信号自适应分解估计方法—变分模态分解(variational mode decomposition, VMD)。VMD 有较好的分解效果和鲁棒性,应用于风速预测领域。运用普通神经网络预测时,训练过程易陷入局部最优,发生过拟合使预测结果失真,难以挖掘冷负荷序列的长时序关系。循环神经网络可有效进行该方面预测,但是容易出现“梯度消失”现象。Zhao 等人^[18]提出的 GRU(gate recurrent unit)门控循环单元网络,通过引入门控单元解决梯度消失问题,更完整考虑时间序列中长短期依赖性关系,相较于 LSTM 具有更快收敛速度,因此也逐渐应用到短期冷负荷预测领域。然而,当输入的时间序列较长时,LSTM、GRU 等 RNN 系列网络处理高维信息难以有效提取数据间信息,影响模型准确率^[19]。

笔者结合 VMD 与 GRU 优势,提出 VMD-GRU 冷负荷预测模型,有效解决特征信息的提取,用于大型公共建筑冷负荷预测,并展开以下研究:

- 1) 构建 VMD-GRU 冷负荷预测模型,使用 VMD 将原始数据序列分解为独立固有模式函数,用 GRU 对每个分量进行预测,将分量预测结果相加得出冷负荷预测值。
- 2) 以西安某大型公共建筑相关数据为例进行实例分析,对模型的输入变量进行相关性分析,选取对冷负荷影响较大的输入变量。
- 3) 采用 VMD-GRU 模型进行冷负荷预测,与其他预测模型进行比较,验证模型的有效性。

1 VMD-GRU 能耗预测模型的构建

VMD 模型依据序列数据的特点逐级进行平稳处理,GRU 网络具有较强的非线性拟合能力,VMD-GRU 模型处理冷负荷的非线性拟合及预测,降低复杂度的同时提升模型预测精度。

1.1 VMD 分解

变分模态分解是一种新型非平稳信号自适应分解估计方法,目的是将原始复杂信号分解为 K 个调幅调频子信号。将大型公建冷负荷相关变量 $\mathbf{X} = [X_1, X_2, \dots, X_m]$ 进行 Pearson 相关性分析,选取相关性高的数据重组为新的相关性序列 $\mathbf{Y} = [U_1, U_2, \dots, U_n, O]$ 。利用 VMD 进行分解及平稳化处理,分解为表示原始数据特征的多个分量。VMD 分解的具体步骤如下

步骤一:初始化各模态、中心频率和算子。

步骤二:根据式(1)和(2),更新参数 u_k 和 ω

$$\hat{u}_k^{n+1} = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (1)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega}, \quad (2)$$

其中: $\hat{f}(t)$ 为原始信号; u_k 是信号 $f(t)$ 的第 k 个分量; $\hat{f}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{\lambda}(\omega)$ 和 \hat{u}_k^{n+1} 分别代表 $f(\omega)$ 、 $u_i(\omega)$ 、 $\lambda(\omega)$ 和 u_k^{n+1} 的傅里叶变换; n 代表迭代次数。

步骤三:根据式(3)更新参数 λ ,

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \pi \left[\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1} \right]. \quad (3)$$

步骤四:对于给定的判别精度 $e > 0$,若 $\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < e$,则停止迭代,否则返回步骤二。

1.2 门控循环单元网络

GRU 网络是长短期记忆网络(long short-term memory, LSTM)的一种变体。通过使用“门”结构,极大避免梯度消失现象。GRU 网络包括更新门、重置门和输出门 3 个部分。它将 LSTM 网络中的遗忘门和输入门合并成 z_t ,原有重置门 r_t ,LSTM 门控网络的优点更新细胞状态和隐藏状态。

Step1:更新门 r_t 和重置门 z_t 。

更新门 z_t 是过去时刻特征信息对现在特征信息的影响程度,阈值越大说明前时刻特征信息对现在影响越大,如式(4)。重置门 r_t 是过去时刻状态特征信息被丢弃的程度,阈值越小说明对过去信息丢弃越多,有助于学习序列中短期的时序特征,见式(5)。其中 h_{t-1} 表示前一时刻的隐藏状态, σ 表示 sigmoid 激活函数, \mathbf{W} 为输入的权重向量。

$$r_t = \sigma(\mathbf{W}_r \times [h_{t-1}, x_t]), \quad (4)$$

$$z_t = \sigma(\mathbf{W}_z \times [h_{t-1}, x_t]). \quad (5)$$

Step2:候选隐藏状态

\tilde{h}_t 为候选隐藏状态,与 h_{t-1} 、 r_t 有关,当 r_t 的取值接近于 0,上一刻信息则被选择遗忘,见式(6)。

$$\tilde{h}_t = \tanh(\mathbf{W}_h \times [r_t \times h_{t-1}, x_t]). \quad (6)$$

Step3:隐藏状态

h_t 为当前隐藏状态,取决于 h_{t-1} 和 \tilde{h}_t 。如果 z_t 趋近于 0,表示上一时刻信息被遗忘;如果 z_t 趋近于 1,表示当前输入信息被遗忘,见式(7)。

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t. \quad (7)$$

Step4:输出

$$y_i = \sigma(W_0 \times h_i) \quad (8)$$

过去的冷负荷状态会对当前状态产生长期影响,GRU 通过控制与更新门限层控制模型的记忆能力,在不断迭代中,对历史数据的特征信息进行记忆与更新,历史数据会被赋予不同的权重值,已经训练的模型会对接下来的数据进行预测。




图 1 预测模型结构

Fig. 1 Forecast model structure

$u_{n1}, u_{n2}, \dots, u_{nk}$ 分别是系统 n 个不同输入变量的观测值, o'_k 是模型输出的观测值, GRU 神经网络的输入向量。将历史数据依次通过多层 GRU 全连接层,并在接下来通过完全连接层合并特征,生成预测当前时刻后 m 个采样周期的输出。将 GRU 神经网络的预测值与真实值之间的平均平方差定义为损失函数,随时间反向传播。

1.3 相关性分析

选用 Pearson 分析法对冷负荷和输入变量间的相关性进行分析。公式为

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (9)$$

式中: r_{xy} 为 2 个变量的相关系数; x_i, y_i 分别为 2 个变量的第 i 个数据点; \bar{x}, \bar{y} 分别为 2 个变量的均值; n 为该变量中数据个数。

1.4 VMD-GRU 预测模型

VMD-GRU 模型的构建分为 4 部分: VMD 分解、分解分量重构、GRU 网络训练及最终预测结果输出。使用 VMD 对冷负荷序列和变量进行相关性分析,舍弃相关性低的变量,对相关性高的变量和冷负荷序列进行 VMD 分解,将分解后的分量进行重组。选取所有相关性高的变量第一个分量作为输入,冷负荷分解后的第一分量作为输出,在 GRU 网络中对预测模型进行训练,依次类推,对第二分量、第三分量等分别进行训练。对冷负荷预测数据相关性高的变量进行 VMD 分解,输入 GRU 网络中进行预测,得到冷负荷的预测分量 $o'_{(n)}$,将分量预测值叠加得到预测值并输出结果,见式(10)。

$$o' = o'_{(1)} + o'_{(2)} + \dots + o'_{(n)} \quad (10)$$

2 案例分析

2.1 项目介绍

实验数据来源于某大型公共建筑,建筑物高 40.6 m,总建筑面积 $258 \times 10^4 \text{ m}^2$,商业面积 $20 \times 10^4 \text{ m}^2$,建筑空调面积 $18.76 \times 10^4 \text{ m}^2$ 。首先对输入变量进行相关性分析,选取出对负荷影响较大的输入变量。

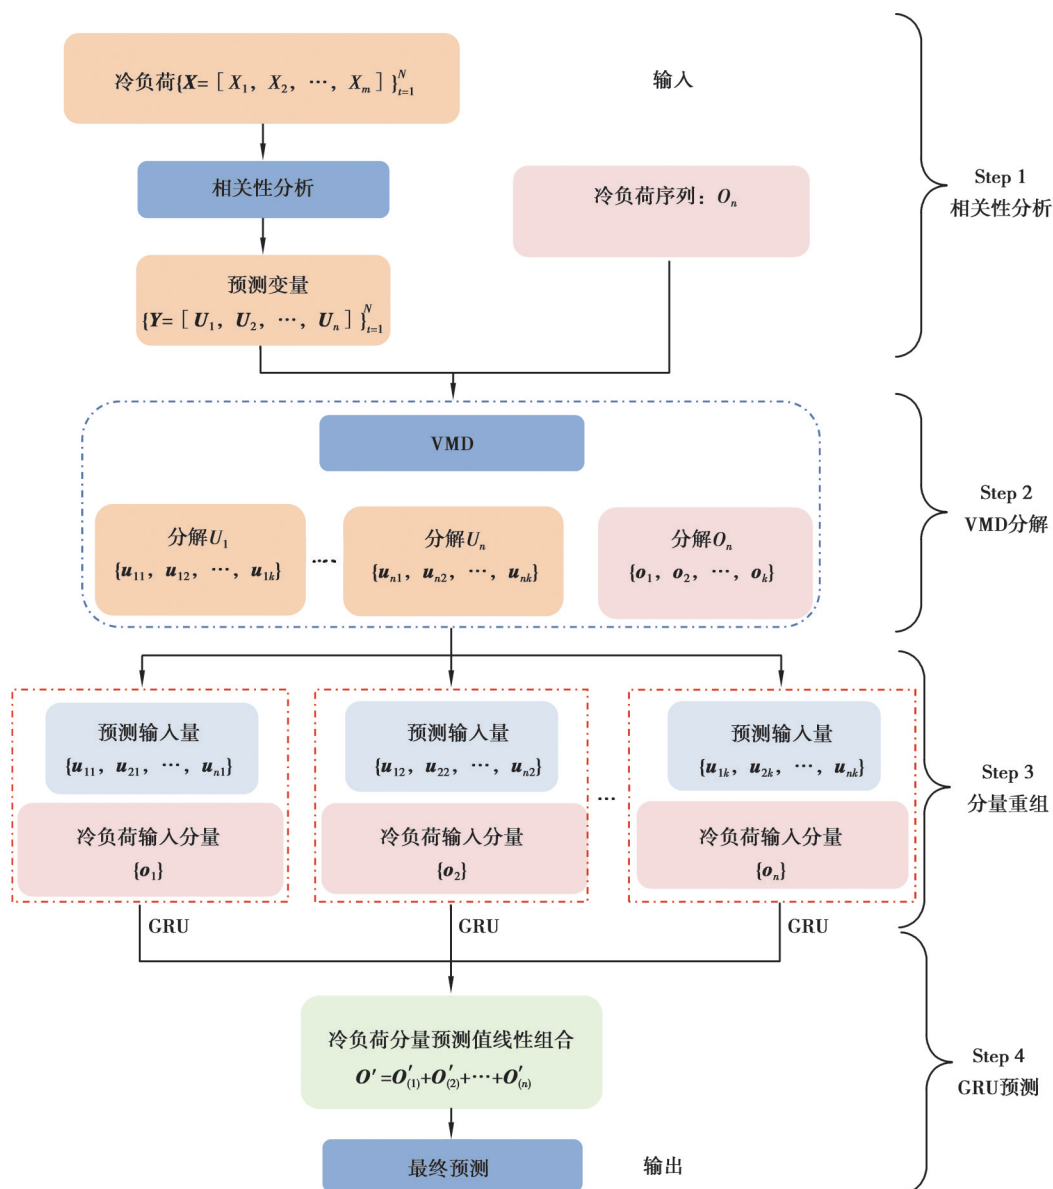


图2 方法流程图

Fig. 2 Flow chart of the method

2.2 相关性分析

大型公共建筑冷负荷预测训练样本的输入层节点考虑到太阳辐射、室外温度导致建筑冷负荷存在滞后,预测模型中加了 $(T-1)$ h时刻室外空气温度^[20],加入 $(T-1)$ h时刻冷负荷以及 $(T-2)$ h时刻冷负荷作为模型输入变量。

实验以6月、7月60天中前50天每天14h运行数据做为训练数据,采用7月份的25、26、27、28数据作为验证分析数据,使用Pearson相关性分析法对其相关性进行分析。

如图3为变量之间的相关性热点图。冷负荷与1h前的太阳辐射强度相关性 R 为0.47093,冷负荷与相对湿度相关性 R 为-0.21487,大多数公共建筑墙体表面会采用隔热材料维持室内在一定时间的热湿环境,在短周期内外界环境的太阳辐射对于墙体温度变化效果不明显,墙体温度变化对室内温度影响较小,因此选择舍弃;冷负荷与室外风速的相关性 R 为-0.05391,相关性较低,这是由于大多数建筑室内本身处于相对密闭的空间,与外界空气流动时间较短,热交换较少,室外风速对于冷负荷的影响较小,在进行冷负荷预测时选择舍弃^[21-23]。最终选取的输入变量为 X_1, X_2, X_3, X_4 和 X_5 ;输出变量为 O ,具体变量选取见表1。

表 1 选取的变量
Tab.1 Selected Variables

相关性分析前		相关性分析后	
变量	变量解释	变量	变量解释
O	T 时刻冷负荷	U_1	$T-1$ h冷负荷
X_1	$T-1$ h时刻冷负荷	U_2	$T-2$ h冷负荷
X_2	$T-2$ h时刻冷负荷	U_3	T h室外温度
X_3	T 时刻室外温度	U_4	$T-1$ h室外温度
相关变量	X_4	U_5	T 时刻太阳辐射强度
	X_5		
	X_6	O	T 时刻冷负荷
	X_7		
	X_8		




图 3 变量间相关性热点图

Fig. 3 Hot spot map of Inter-variable correlation

2.3 VMD 冷负荷序列分解

经过相关性分析后,提取 5 个相关性较高的变量反映原始数据的主特征,进行 VMD 分解。参数设置,确定模态数量,按照实验选择模态数量对冷负荷序列进行 VMD 分解,获取 VMD 结果。

参数设置为:惩罚参数 $\alpha=1\ 000$;初始中心频率 $\omega=0$;收敛判据 $r=10^{-6}$ 。在分解时出现相近模态时容易出现混叠现象。模态函数个数经过反复实验得出表 2,看出在模态分量个数为 6 时,中心频率 2 288 Hz 和 2 336 Hz 相距较近,出现模态混叠^[24]。为了分解原始冷负荷序列,且不出现模态混叠,模态个数选为 5 较适宜。5 条分量依次为 u_1, u_2, \dots, u_5 ,且各 u 分量按照中心频率从低到高依次排列。每条 u 分量反映出不同信息, u_1 是频率最低的一条分量,含有原始序列的趋势信息, u_5 是频率最高分量,包含着原始序列的震荡信息。

对冷负荷序列进行 VMD 分解,分解结果如图 4 所示。模态函数 u_1 表示趋势分量,平均振幅较大,变化平缓,规律性最易掌握,反映检测样本中冷负荷的大体变化趋势。模态函数 u_2, u_3 表示细节分量,规律性较好,周期性明显,表明建筑冷负荷具有较强周期特性,规律性较强,波动平缓。模态函数 u_4 和 u_5 平均振幅最小,波动较大,规律性较差,受建筑人员活动影响较强,具有随机性。

表2 不同 K 值对应的中心频率Tab.2 Center frequency corresponding to different K

模态个数		中心频率					
2	6	1 452	-	-	-	-	-
3	2	675	2 548	-	-	-	-
4	1	662	1 444	3 278	-	-	-
5	1	641	1 381	2 420	3 750	-	-
6	1	640	1 368	2 288	2 336	3 827	-

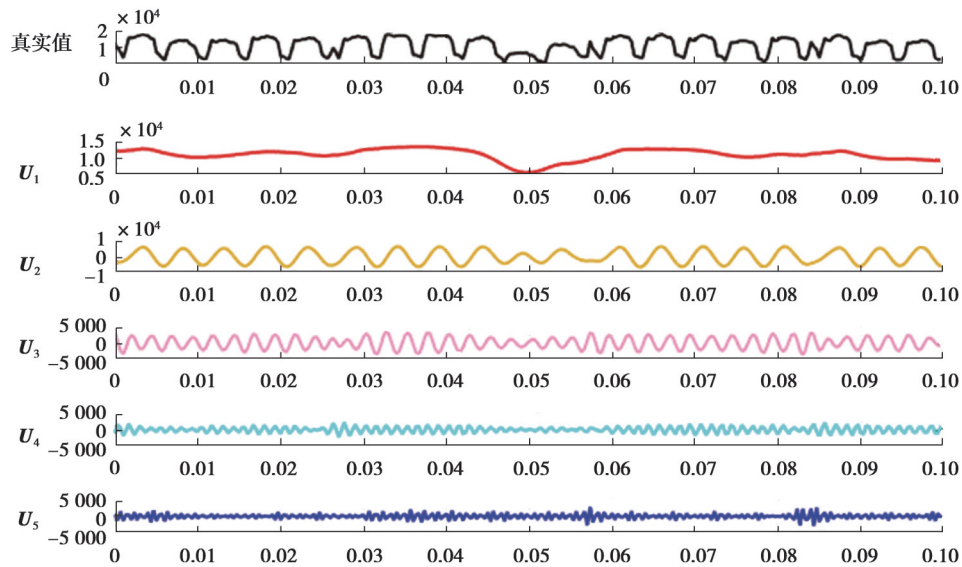


图4 冷负荷VMD分解图

Fig. 4 The decomposed results of cooling load by VMD

3 实验与分析

基于VMD-GRU的大型公共建筑冷负荷预测,是将VMD分解的每一个分量分别采用GRU网络进行预测,最终获得所有冷负荷预测分量相加求和,得到冷负荷预测结果。为验证所提出模型的有效性,采用研究模型分别与BP、GRU、EMD-BP、VMD-BP、EMD-GRU模型进行实验对比分析。经过实验参数调试比较,GRU网络设置2个隐含层为最佳,激活函数为sigmoid,学习率为0.05,迭代次数为1500,时间步的长度为28,最终设置GRU网络为5-3-7-1。

由于很多输入向量与预测结果相关性差、信息冗余度高等原因,导致多数预测模型在预测精度上未达到理想预测效果^[25]。首先对输入向量进行相关性分析,在众多输入向量中剔除冷负荷预测影响较小的向量,将剩余关键因素作为模型预测输入向量。由表3中相关性前后的实验数据分析可知,将输入向量由8个降到5个,精度提高,说明被剔除的3个输入向量降低了模型预测精度,属于冗余信息。

图5中 $u_{(1-5)}$ 为子序列预测结果,5个分量序列进行累加可得到VMD-GRU模型冷负荷预测序列,并且和原始冷负荷序列进行对比。由图5分析可知,冷负荷预测分量累加之后获得VMD-GRU模型的预测结果非常接近于冷负荷原始值。接下来对提出的VMD-GRU预测模型和另外几个模型进行对比分析。

图6展示6种模型的预测结果,通过比较分析可知,单一BP、GRU预测模型预测结果不稳定,偏差较大。EMD-BP、VMD-BP和EMD-GRU预测模型虽然预测结果偏差有所降低,但是与VMD-GRU预测模型相比,预测精度不够好。采用VMD-GRU预测模型的预测精度高于其它5种模型,该模型得出的预测值与真实值更接近。

表 3 不同模型预测效率对比

Tab. 3 Comparison of prediction efficiency of different models

实验模型	训练迭代次数	相关性分析前			相关性分析后		
		训练时间/s	测试时间/s	MAE	训练时间/s	测试时间/s	MAE
BP 模型	1 500	56.79	0.60	1 982.473	37.86	0.54	1 924.206
GRU 模型		44.95	0.58	1 881.445	34.58	0.42	1 813.956
EMD-BP 模型		84.69	1.00	1 243.514	70.58	0.63	1 157.865
VMD-BP 模型		80.16	0.88	1 305.724	60.83	0.59	1 126.459
EMD-GRU 模型		77.26	0.79	1 149.968	60.79	0.57	1 082.471
VMD-GRU 模型		58.45	0.63	563.766	42.66	0.49	495.532

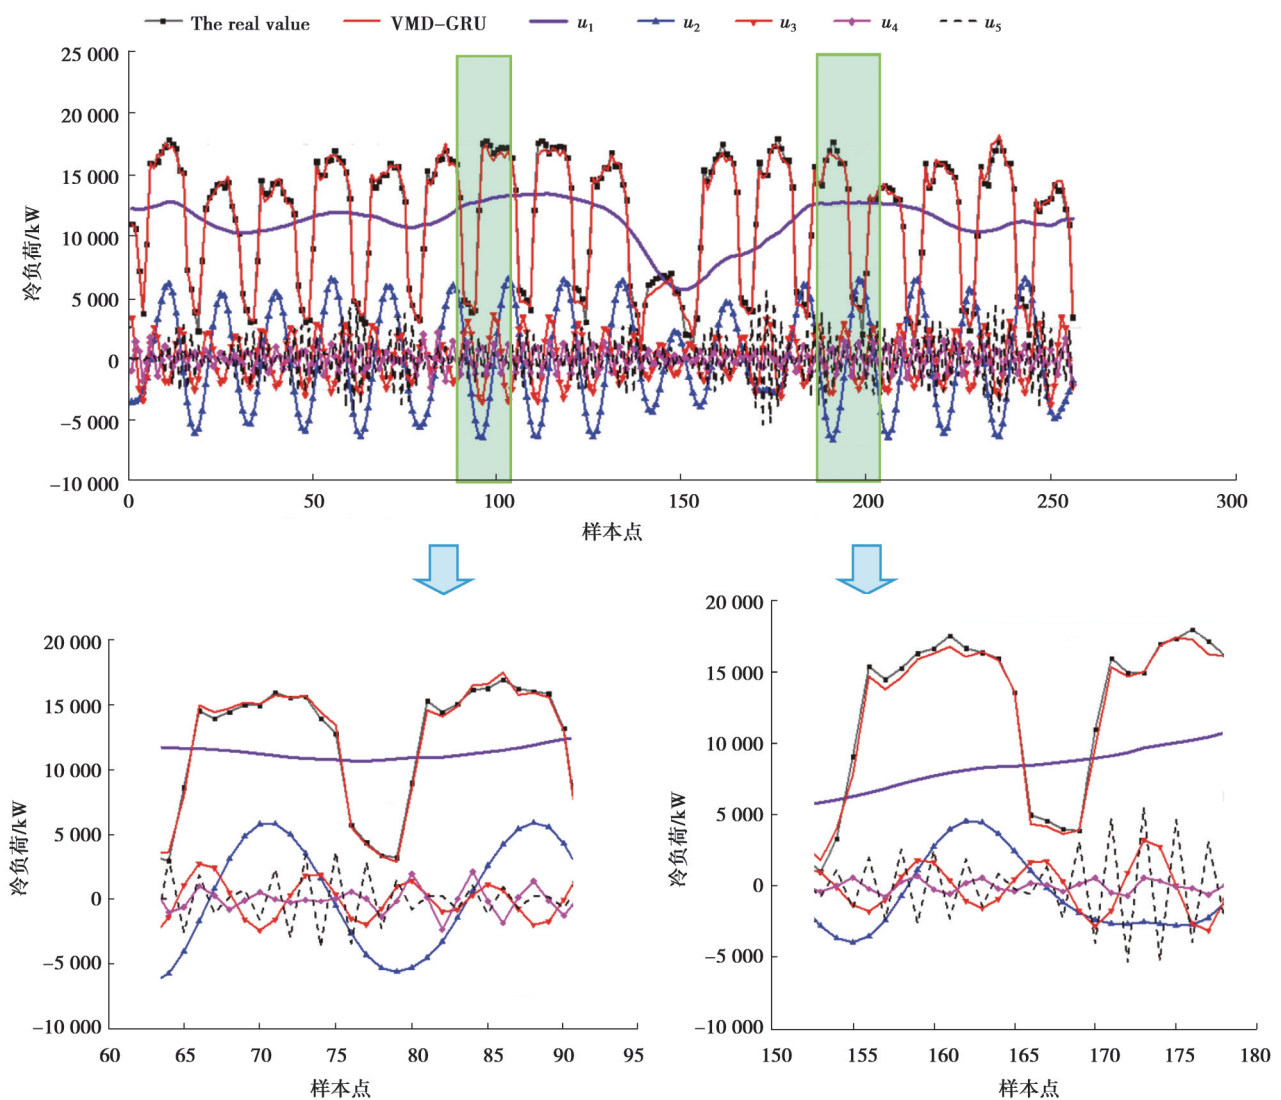


图 5 冷负荷预测结果

Fig. 5 Prediction results of cooling load

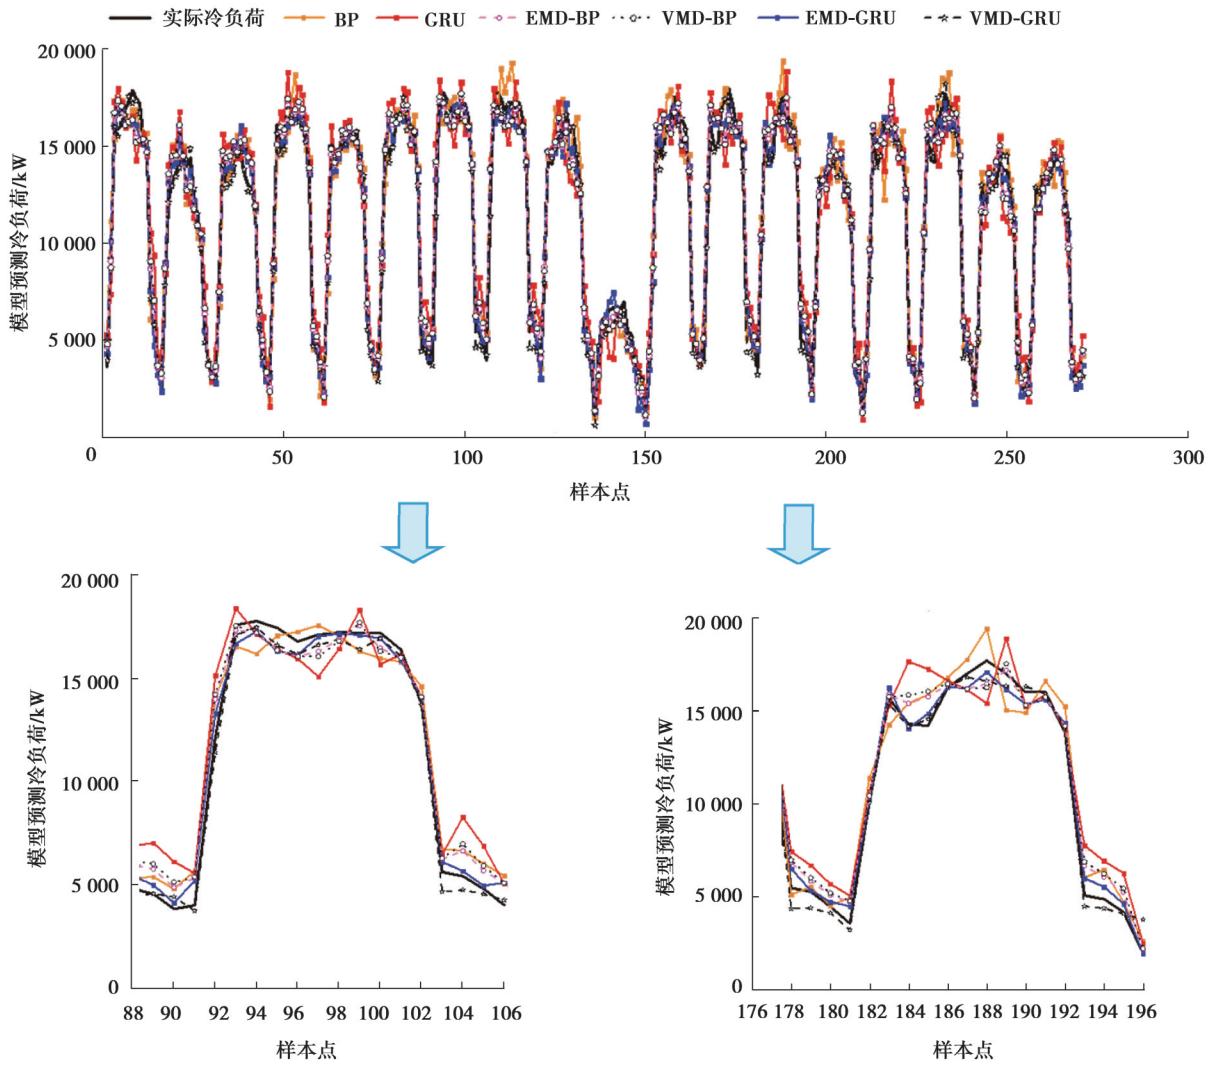


图6 6种模型的预测结果对比

Fig. 6 Comparison of prediction results of six models

图7可见6种预测模型误差对比,将6种模型的预测误差序列采用Kolmogorov-Smirnow检验^[26],测试结果表明4个序列均服从正态分布。BP和GRU在高误差区出现的次数较多,误差分布较分散。通过EMD和VMD分解后,预测值误差较小。VMD分解后的预测值误差比EMD更小,优化效果明显。VMD-GRU预测模型的相对误差远小于其他预测模型。

传统BP神经网络单独使用预测效果不能很好挖掘时间序列中的长时序关系。GRU引入门控单元可很好挖掘其中的长短期时序关系^[27]。VMD通过迭代搜寻变分模型最优解确定模态函数序列分量,具有较强长时序趋势特征^[28],将VMD与GRU结合可较好挖掘冷负荷序列中的长时序关系特征,有利于提高预测精度。通过图7和表4分析可知,在实验中BP预测性能较优于GRU,但在实际预测中往往需要考虑到冷负荷序列中的长时序关系,BP神经网络在预测中不能够充分利用数据本身存在的长时序关系。VMD与GRU结合可以更加有效,助于提高模型预测精度,BP与VMD和EMD等分解算法结合时不能有效利用长时序关系特征,不利于提高模型预测精度。

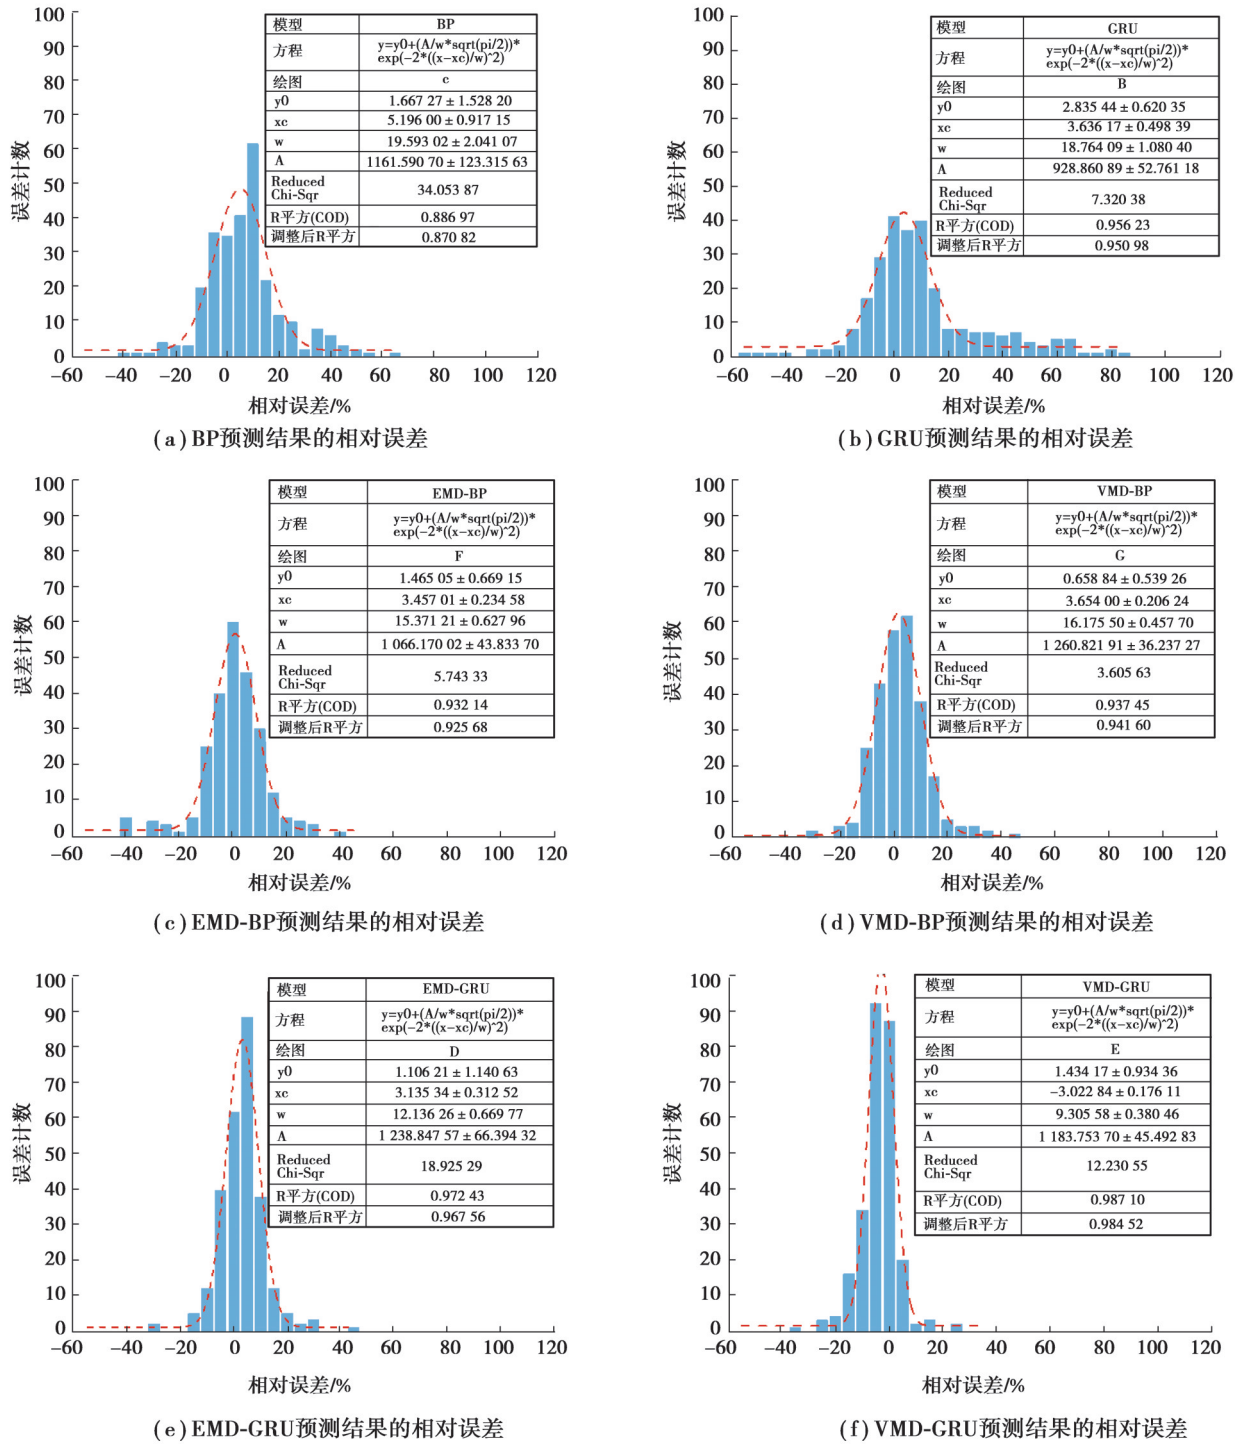


图 7 6种模型的预测相对误差的对比

Fig. 7 Comparison of prediction relative errors of the six models

在正态分布中 μ 值决定了曲线位置, $|\mu|$ 越接近0,说明位置越靠近0,即大多数的预测相对误差值接近于0,模型预测效果越好。 σ 决定了曲线的尖峭程度, σ 越小图形越尖峭,说明在该误差范围内的包含数值越多。通过对6个模型的相对误差分布图形对比可知, VMD-GRU模型 $|\mu| = 3.022\%$,最接近于0,并且 σ 最小,说明该预测模型的相对误差在0附近数量值最大,模型最精确。


图8对比GRU预测模型和EMD-GRU预测模型, VMD-GRU模型更加逼近真实值。表5中对6个模型进行比较, VMD-GRU模型线性回归拟合曲线拟合度最高,达到了0.992,残差和较小达到1.045。通过分析其截

距和斜率可知,VMD-GRU模型预测值和真实值的拟合曲线更加接近直线 $y=x$,说明预测效果最好,且该模型的截距标准误差最小,说明其截距误差范围最小,预测值更加接近真实值。


表4 6种相对误差预测模型拟合曲线比较

Tab. 4 Comparison of six relative error prediction model fitting curves


实验模型	拟合曲线	μ	σ	拟合 r^2
BP模型	$y = 2.835 + \frac{928}{18.764 \times \sqrt{2\pi}} e^{-2 \times \left(\frac{x-3.636}{18.764}\right)^2}$	-3.636%	18.764	0.951
GRU模型	$y = 1.667 + \frac{1\,167.591}{19.593 \times \sqrt{2\pi}} e^{-2 \times \left(\frac{x-5.196}{19.593}\right)^2}$	5.196%	19.593	0.871
EMD-BP模型	$y = 1.465 + \frac{1.465}{15.371 \times \sqrt{2\pi}} e^{-2 \times \left(\frac{x+3.457}{15.371}\right)^2}$	3.457%	15.371	0.926
VMD-BP模型	$y = 0.658 + \frac{1\,260.8\,219}{16.176 \times \sqrt{2\pi}} e^{-2 \times \left(\frac{x+3.654}{16.176}\right)^2}$	3.654%	16.176	0.942
EMD-GRU模型	$y = 1.106 + \frac{1\,283.848}{12.136 \times \sqrt{2\pi}} e^{-2 \times \left(\frac{x-3.136}{12.136}\right)^2}$	3.136%	12.136	0.968
VMD-GRU模型	$y = 1.434 + \frac{1\,183.7\,537}{9.306 \times \sqrt{2\pi}} e^{-2 \times \left(\frac{x+3.022}{9.306}\right)^2}$	-3.022%	9.306	0.985




(a) 实际与BP模型预测冷负荷的拟合曲线



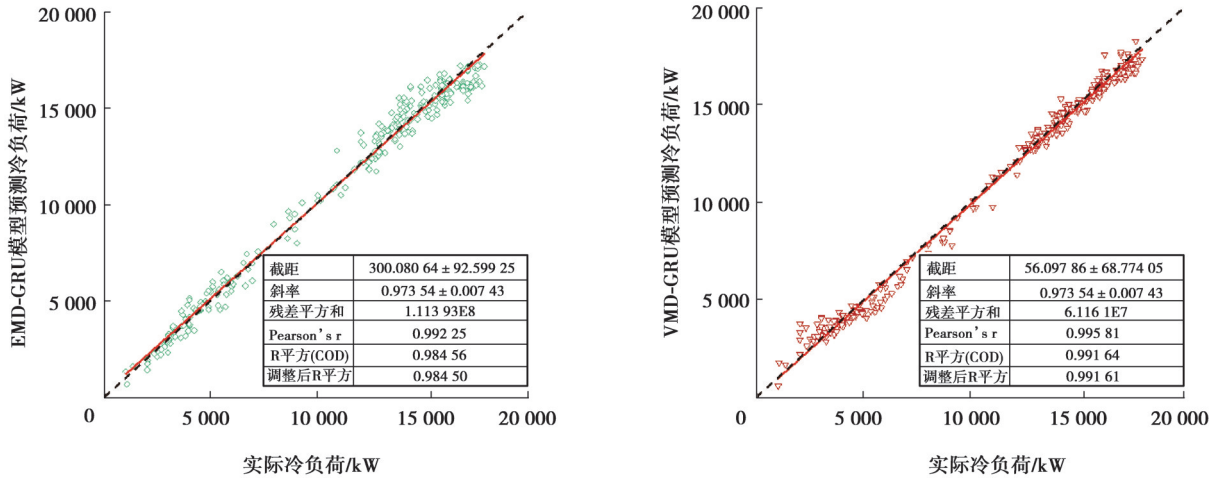
(b) 实际与GRU模型预测冷负荷的拟合曲线



(c) 实际与VMD-BP模型预测冷负荷的拟合曲线



(d) 实际与EMD-BP模型预测冷负荷的拟合曲线



(e) 实际与EMD-GRU模型预测冷负荷的拟合曲线

(f) 实际与VMD-GRU模型预测冷负荷的拟合曲线

图 8 实际冷负荷与模型预测冷负荷的回归拟合曲线

Fig. 8 Cooling load regression fitting curve between actual value and model prediction value

表 5 6种预测模型回归拟合曲线参数比较

Table 5 Comparison of six prediction model regression fitting curve parameters

实验模型	拟合曲线	截距值	标准误差	拟合 r^2
BP 模型	$y = 1\ 231.902 + 0.921x$,	4.917	194.558	0.928
GRU 模型	$y = 587.624.902 + 0.974x$	2.891	149.179	0.961
EMD-BP 模型	$y = 765.991 + 0.947x$ #	2.014	124.519	0.971
VMD-BP 模型	$y = 649.514 + 0.954x$	1.601	111.027	0.977
EMD-GRU 模型	$y = 300.081 + 0.974x$	1.114	92.600	0.985
VMD-GRU 模型	$y = 56.098 + 0.986x$	1.045	68.774	0.992

4 结论

针对大型公共建筑冷负荷预测,提出VMD-GRU预测模型,对输入输出数据间的相关性进行分析,利用VMD算法对冷负荷序列进行初步分解,利用GRU网络对分解序列分别进行预测,得出以下结论:

1)该大型公共建筑的 T 时刻输出冷负荷与 T 时刻室外温度、 $T-1$ 时刻室外温度、 T 时刻太阳辐射量、 $T-1$ 时刻冷负荷、 $T-2$ 时刻冷负荷这5个输入量相关性较高。对变量进行相关性分析,避免人工经验选取输入变量的不足,缩短预测时间。

2)以MAE、MAPE和 r 作为3种预测模型评价标准,实验结果表明,BP、GRU、EMD-BP、VMD-BP、EMD-GRU和VMD-GRU模型的MAE分别为1 924.206、1 813.956、1 157.865、1 126.459、1082.47和495.532;MAPE分别为0.181 6、0.171 8、0.102 5、0.122 5、0.092 7和0.041 9; r 分别为0.515 64、0.525 22、0.803 61、0.793 24、0.781 76和0.954 9。

3)冷负荷时间序列往往是非平稳、非线性。VMD-GRU模型更容易掌握建筑冷负荷时间序列的特征,

实现原始序列平稳化,提高建筑冷负荷预测的精度,更适合工程实际应用。

参考文献

- [1] Liu T, Xu C, Guo Y, Chen H, A novel deep reinforcement learning based methodology for short-term HVAC system energy[J]. International Journal of Refrigeration,2019,107(3): 39-51.
- [2] 王焯,白玉洁,闫若文.不同通风模式下变温度送风的节能特性研究[J].重庆大学学报,2020,43(5):40-49.
Wang Y, Bai Y J, Yan R W. Study on energy saving characteristics of variable temperature air supply under different ventilation modes[J]. Journal of Chongqing University, 2020, 43(5): 40-49.(in Chinese)
- [3] Dong B, Li Z X, Mahbobur Rahman S M, et al. A hybrid model approach for forecasting future residential electricity consumption[J]. Energy and Buildings, 2016, 117: 341-351.
- [4] Yildiz B, Bilbao J I, Sproul A B. A review and analysis of regression and machine learning models on commercial building electricity load forecasting[J]. Renewable and Sustainable Energy Reviews, 2017, 73: 1104-1122.
- [5] Fumo N. A review on the basics of building energy estimation[J]. Renewable and Sustainable Energy Reviews, 2014, 31: 53-60.
- [6] 钱志.基于改进型SVR的电网短期负荷预测[J].中国电力,2016,49(8):54-58.
Qian Z. Short-term load forecasting of power grid based on improved SVR[J]. Electric Power, 2016, 49(8): 54-58.(in Chinese)
- [7] 李军,黄杰.基于自组织映射神经网络的局部自回归方法在网络流量预测中的应用[J].信息与控制,2016,45(1):120-128.
Li J, Huang J. Prediction of network traffic using local auto-regressive methods based on self-organizing map neural network [J]. Information and Control, 2016, 45(1): 120-128.(in Chinese)
- [8] 杨祖菘,丁洁,刘晋峰.一种新的结合卷积神经网络的隧道内停车检测方法[J].重庆大学学报,2021,44(6):49-59.
Yang Z L, Ding J, Liu J F. A new tunnel vehicle stopping detection methodology combined with convolutional neural network [J]. Journal of Chongqing University, 2021, 44(6): 49-59.(in Chinese)
- [9] 彭飞,马煜,张晓华,等.基于改进深度森林的短期电力负荷预测模型[J].重庆大学学报,2022,45(5):1-8.
Peng F, Ma Y, Zhang X H, et al. Short term power load forecasting model based on improved deep forest[J]. Journal of Chongqing University, 2022, 45(5): 1-8.(in Chinese)
- [10] Lauster M, Teichmann J, Fuchs M, et al. Low order thermal network models for dynamic simulations of buildings on city district scale[J]. Building and Environment, 2014, 73: 223-231.
- [11] 李军,卓泽赢.基于经验小波变换和多核学习的风电功率短期预测[J].信息与控制,2018,47(4):437-447.
Li J, Zhuo Z Y. Wind power short-term forecasting based on empirical wavelet transform and multiple kernel learning[J]. Information and Control, 2018, 47(4): 437-447.(in Chinese)
- [12] 罗勇,郑金,宁美凤.基于相似日搜索的PSO-WNN组合模型在短期电力负荷预测中的应用[J].信息与控制,2013,42(3):371-376.
Luo Y, Zheng J, Ning M F. Application of PSO-WNN combined model based on similar days searching to short-term electric power load forecasting[J]. Information and Control, 2013, 42(3): 371-376.(in Chinese)
- [13] 杨照坤,宋万清,曹琨.基于量子遗传算法的FARIMA模型电力负荷短期预测[J].传感器与微系统,2019,38(10):143-145.
Yang Z K, Song W Q, Cao K. Short-term prediction of power load based on FARIMA model for quantum genetic algorithm[J]. Transducer and Microsystem Technologies, 2019, 38(10): 143-145.(in Chinese)
- [14] Wang L, Lv S X, Zeng Y R. Effective sparse adaboost method with ESN and FOA for industrial electricity consumption forecasting in China[J]. Energy, 2018, 155: 1013-1031.
- [15] 吴云,雷建文,鲍丽山,等.基于改进灰色关联分析与蝙蝠优化神经网络的短期负荷预测[J].电力系统自动化,2018,42(20):67-72.
Wu Y, Lei J W, Bao L S, et al. Short-term load forecasting based on improved grey relational analysis and neural network optimized by bat algorithm[J]. Automation of Electric Power Systems, 2018, 42(20): 67-72.(in Chinese)
- [16] 李伟,韩力.组合灰色预测模型在电力负荷预测中的应用[J].重庆大学学报(自然科学版),2004,27(1):36-39.
Li W, Han L. Application of combination grey model in power load forecasting[J]. Journal of Chongqing University (Natural Science Edition), 2004, 27(1): 36-39.(in Chinese)
- [17] Wang J J, Li Y N. Multi-step ahead wind speed prediction based on optimal feature extraction, long short term memory neural network and error correction strategy[J]. Applied Energy, 2018, 230: 429-443.

- [18] 赵兵,王增平,纪维佳,等.基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J].电网技术,2019,43(12):4370-4376.
Zhao B, Wang Z P, Ji W J, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU[J]. Power System Technology, 2019, 43(12): 4370-4376.(in Chinese)
- [19] 钟波,赵渊,周家启.基于粗神经网络的电力系统可靠性评估方法[J].重庆大学学报(自然科学版),2005,28(7):38-42.
Zhong B, Zhao Y, Zhou J Q. Methods of power systems reliability assessment based on rough neural network[J]. Journal of Chongqing University (Natural Science Edition), 2005, 28(7): 38-42.(in Chinese)
- [20] 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.
- [21] Escrivá -Escrivá G, Álvarez-Bel C, Roldán-Blay C, et al. New artificial neural network prediction method for electrical consumption forecasting based on building end-uses[J]. Energy and Buildings, 2011, 43(11): 3112-3119.
- [22] 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.
- [23] 王蓓蓓,朱峰,嵇文路,等.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, et al. 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)
- [24] Zhang Y G, Chen B, Pan G F, et al. A novel hybrid model based on VMD-WT and PCA-BP-RBF neural network for short-term wind speed forecasting[J]. Energy Conversion and Management, 2019, 195: 180-197.
- [25] 杨熊,于军琪,郭晨露,等.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[J].土木与环境工程学报(中英文),2019,41(1):168-174.
Yang X, Yu J Q, Guo C L, et al. Dynamic load forecasting model of ice storage air conditioning based on improved PSO-BP neural network[J]. Journal of Civil and Environmental Engineering, 2019, 41(1): 168-174.(in Chinese)
- [26] Maier M, Brückmann A, Schleußner E, et al. Using critical flicker frequency in the evaluation of visual impairment in preeclamptic women[J]. European Journal of Obstetrics & Gynecology and Reproductive Biology, 2017, 211: 188-193.
- [27] Gao S A, Huang Y F, Zhang S, et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation[J]. Journal of Hydrology, 2020, 589: 125188.
- [28] Zhang Y G, Zhao Y, Kong C H, et al. A new prediction method based on VMD-PRBF-ARMA-E model considering wind speed characteristic[J]. Energy Conversion and Management, 2020, 203: 112254.

(编辑 侯 湘)