

文章编号: 2095-2163(2023)09-0037-07

中图分类号: TP183

文献标志码: A

基于神经网络的建筑能耗预测

吴 焱¹, 陈湘萍¹, 蔡永翔²

(1 贵州大学 电气工程学院, 贵阳 550025; 2 贵州电网有限责任公司电力科学研究院, 贵阳 550007)

摘要: 建筑能耗约占中国总能耗的 40%, 为实现建筑节能, 准确有效的能耗预测是有必要的。本文基于 EnergyPlus 软件建立建筑空间模型和供暖、通风和空气调节系统; 以能耗模拟数据为基础, 建立长短期记忆网络预测模型; 以平均绝对误差 MAE、均方误差 MSE 和均方根误差 RMSE 作为评价指标, 并与 BP 神经网络预测模型进行对比。实验结果表明, 基于“每天”数据和“每小时”数据, LSTM 神经网络预测模型不论预测精确度还是评估指标都优于 BP 神经网络预测模型, 说明 LSTM 神经网络在处理时间序列数据比 BP 神经网络更有优势, 能更好地反映建筑能耗的变化趋势。

关键词: 能耗预测; 建筑能耗; LSTM 神经网络; EnergyPlus

Building energy consumption prediction based on neural network

WU Ye¹, CHEN Xiangping¹, CAI Yongxiang²

(1 The Electrical Engineering College of Guizhou University, Guiyang 550025, China;

2 Electric Power Research Institute of Guizhou Power Grid Co., Ltd., Guiyang 550007, China)

[Abstract] Building energy consumption accounts for about 40% of China's total energy consumption. This paper builds a building space model and a Heating Ventilation and Air Conditioning (HVAC) system based on EnergyPlus software and establishes a Long Short-Term Memory Network (LSTM) prediction model based on energy consumption simulation data. The LSTM prediction model is evaluated by using the mean absolute error MAE, mean square error MSE and root mean square error RMSE as indicators, and compared with the BP (Back Propagation) neural network prediction model. The experimental results show that the LSTM neural network prediction model is better than the BP neural network prediction model in both prediction accuracy and evaluation index, indicating that the LSTM neural network prediction model is more advantageous than the BP neural network prediction model and can better reflect the change trend of building energy consumption.

[Key words] Energy consumption prediction, Building energy consumption, LSTM neural network, EnergyPlus

0 引言

随着社会的进步, 经济的发展, 建筑能耗也在快速增长, 据统计全球的建筑能耗约占总能耗的 40%^[1], 而中国建筑能耗约占中国能源消耗的 21.7%^[2]。确有效的建筑能耗预测是节能的基础^[3]。

国内外学者对能耗预测进行了大量的研究, 目前常用神经网络来进行能耗预测。Kawashima 等^[4]提出了基于神经网络的每小时负荷预测进行预测控制, 并与传统机器学习方法进行对比, 得出神经网络有更好效果的结论; 许馨尹等^[5]基于 EnergyPlus 软件对办公建筑在气候变化的情况下进行能耗模拟, 结果表明气候对建筑能耗有影响; Amber 等^[6]建立

多元回归模型对用电能耗进行模拟, 结果表明环境温度对于建筑能耗有着显著影响。

在基于机器学习方法的能耗预测中, 张卓渊^[7]提出一种基于生成对抗网络的建筑能耗预测方法, 以 LSTM (Long Short-Term Memory Network) 神经网络为生成器, 卷积神经网络 (CNN) 为判别器, 对比其他模型有着更高的精度; 井文强等^[8]针对局部最优问题, 提出改进灰狼优化 BP (Back Propagation) 神经网络的预测模型, 通过改变原始收敛因子使得该模型有较好的精度和泛化能力; 曾国治等^[9]基于 CNN 的特征提取能力和循环神经网络 (RNN) 的时序学习能力, 提出了 CNN-RNN 模型来预测建筑能耗, 效率提高的同时还有不错的精度; 邵必林等^[10]基于注意力机制和

基金项目: 国家自然科学基金 (51867007)。

作者简介: 吴 焱 (1998-), 男, 硕士研究生, 主要研究方向: 控制工程; 陈湘萍 (1977-), 女, 博士, 教授, 主要研究方向: 新能源与节能技术。

通讯作者: 陈湘萍 Email: ee.xpchen@gzu.edu.cn

收稿日期: 2022-11-19

LSTM 神经网络建立预测模型,更好的捕捉重要信息并反映变化趋势。总的来说,基于机器学习的能耗预测主要是用 LSTM 神经网络、BP 神经网络,又或者用优化算法优化后神经网络,例如基于粒子群优化算法(PSO)进行优化、基于灰狼算法(GWO)优化以及基于 LM(Levenberg-Marquardt)算法优化等。

EnergyPlus 软件是美国能源部和劳伦斯·伯克利国家实验室基于 BLAST 和 DOE-2 基础上开发的建筑能耗模拟软件,能够用于对建筑的采暖、制冷、照明以及其他能源消耗进行能耗模拟分析,也可以进行二次开发,增加新功能,满足使用者多样化的需求^[11]。

综上所述,目前针对能耗预测用的最多的就是神经网络。本文基于 EnergyPlus 模拟获得能耗数据,考虑到能耗数据是一个长时间序列数据,因此在神经网络的选择上选择了处理长时间序列较其他神经网络有优势的长短期记忆网络(LSTM)来建立能耗预测模型,通过平均绝对误差 MAE,均方误差 MSE 以及均方根误差 RMSE 来判断训练网络预测的精度,并与传统 BP 神经网络预测模型进行对比,验证预测结果的准确性。

1 LSTM 神经网络与数据获取

1.1 LSTM 神经网络介绍

LSTM 是神经网络的一个变体,解决了传统神经网络在处理长时间序列时出现的梯度消失和梯度爆炸问题^[12]。LSTM 单元结构图如图 1 所示。

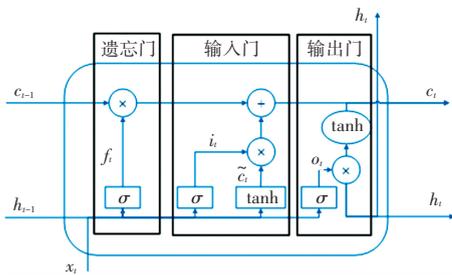


图 1 LSTM 单元结构图

Fig. 1 LSTM unit structure diagram

LSTM 的门控结构如图 2 所示。LSTM 通过遗忘门、输入门和输出门这 3 个特殊的门控结构来实现信息的保护和控制^[13]。

遗忘门如图 2(a)所示,遗忘门会读取上一时刻的输出 h_{t-1} 和当前的输入 x_t , f_t 输出的值来确定 C_{t-1} 是否丢弃,其计算如式(1):

$$f_t = \sigma(\mathbf{W}_f * [h_{t-1}, x_t]) + \mathbf{b}_f \quad (1)$$

其中, σ 代表的是 Sigmoid 激活函数; \mathbf{b}_f 代表偏置向量; \mathbf{W}_f 代表遗忘门权重系数矩阵。

输入门如图 2(b)所示,实现信息更新需要两个步骤,一是通过 Sigmoid 层确定更新信息,再由 tanh 层确定备用更新内容;二是结合两部分生成的信息对 C_t 进行一个更新。其计算如式(2)~式(4):

$$i_t = \sigma(\mathbf{W}_i * [h_{t-1}, x_t]) + \mathbf{b}_i \quad (2)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c * [h_{t-1}, x_t]) + \mathbf{b}_c \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

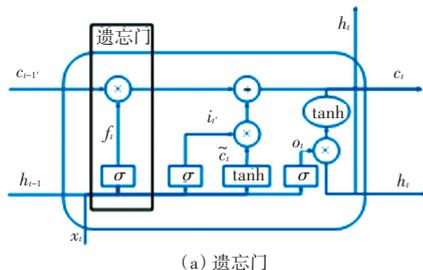
其中, \tanh 代表双曲正切激活函数; \mathbf{W}_i 和 \mathbf{W}_c 分别代表由 σ 和 \tanh 确定的输入门权重系数矩阵; \mathbf{b}_i 和 \mathbf{b}_c 分别代表由 σ 和 \tanh 确定的偏置向量; C_t 代表当前的状态。

输出门如图 2(c)所示,通过运行 Sigmoid 激活函数得到 o_t 值,将当前的状态 C_t 经过 tanh 函数处理后的值与 o_t 值相乘得到 h_t , 得到 t 时刻的输出,并且也作为下一时刻的输入,如式(5)、式(6):

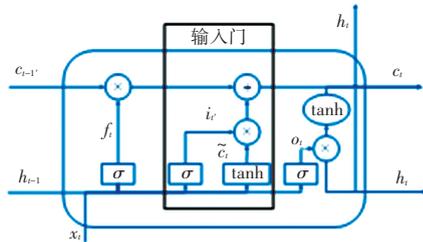
$$o_t = \sigma(\mathbf{W}_o * [h_{t-1}, x_t]) + \mathbf{b}_o \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

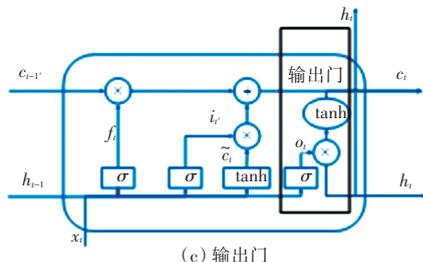
其中, \mathbf{W}_o 代表输出门权重系数矩阵; \mathbf{b}_o 代表偏置向量; o_t 代表的是 t 时刻的输出。



(a) 遗忘门



(b) 输入门



(c) 输出门

图 2 LSTM 的门控结构

Fig. 2 Gating structure of LSTM

1.2 数据获取

本文所用的建筑能耗数据是通过 EnergyPlus 软件模拟得到的,在 EnergyPlus 软件中添加空气回路 (Variable Air Volume, VAV)、冷却水回路(制冷机以及冷却塔)、载热盘管以及锅炉,形成一个简单的供暖、通风和空气调节 (Heating Ventilation and Air Conditioning, HVAC) 系统,并在理想条件下进行能耗模拟。

在 EnergyPlus 软件中设置 HVAC 系统时,主要

是对 Zone、System 以及 Plant 这 3 个对象进行设置。对 VAV 主要在 HVAC Template: System/Zone VAV 里进行设置,在 System VAV 里设置 System Availability Schedule 为 Office HVAC、Cooling Coil Design Setpoint 为 13 °C、Minimum Outdoor Air Schedule Name 为 Office Minimum OA 以及 Economizer Type 为 Fixed Dry Bulb 等,其他具体设置见表 1。

表 1 HVAC 设置表

Tab. 1 HVAC setting table

Modules	Plant	Parameters
HVAC Template: System: VAV	Name	VAV with Reheat
	System Availability Schedule	Office HVAC
	Cooling Coil Design Setpoint	13 °C
	Minimum Outdoor Air Schedule Name	Office Minimum OA
	Economizer Type	Fixed Dry Bulb
	Return Plenum Name	PLENUM
HVAC Template: Zone: VAV	Supply Air Minimum Flow Fraction	0.2
	Reheat Coil Type	VAV with Reheat
	Heating Damper Action	Hot Water
Modules	Plant	Parameters
HVAC Template: Plant: Chilled Water Loop	Condenser Water Temperature Control Type	Specified Setpoint
	Condenser Water Design Setpoint	29.4°C
HVAC Template: Plant: Chiller	Chiller Type	Electric Reciprocating Chiller
	Nominal COP	3.6
HVAC Template: Plant: Tower	Tower Type	Two Speed
HVAC Template: Plant: Hot Water Loop	Name	Hot Water Plant
HVAC Template: Plant: Boiler	Boiler Type	Hot Water Boiler

在 EnergyPlus 软件中建立 HVAC 系统,考虑到 HVAC 系统的复杂度,在本文选用了简单的 HVAC 系统,大部分均采用默认数值,因为建筑有 5 个区,所以 Zone: VAV 要按相同参数设置 5 个区。在办公建筑中,室内负载对能耗影响较大,本文中室内负载包括人员数量、照明设备以及电气设备,其中室内负载见表 2。

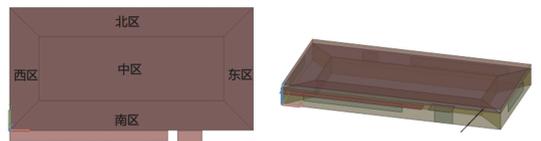
的芝加哥,长 30.5 m、宽 15.2 m、高 3 m,占地面积为 463.6 m²,四面墙上都有窗户。由于建筑空间过大,因此把空间分为东区、西区、北区、南区以及中区,中区到外墙的距离均为 3.7 m,在天花板和 5 个区之间还有一个集气室,建筑围护结构及传热系数见表 3。用 EnergyPlus 软件模拟之前,要选择 USA_IL_Chicago-OHare.Intl.AP.725300_TMY3 天气文件。

表 2 室内负载

Tab. 2 Indoor loads

区域	南区	西区	北区	东区	中区
照明/W	1 584	684	1 584	684	2 964
设备/W	1 056	456	1 056	456	1 976
人数/人	10	5	10	5	20

本文中所示的建筑如图 3 所示,该建筑位于美国



(a) 俯视图 (b) 侧视图

图 3 建筑图

Fig. 3 Architectural drawing

表3 围护结构及传热系数表

Tab. 3 Envelopes and heat transfer coefficients

围护结构	Conductivity 传热系数 (W/m^2k)	Thickness 厚度/m
外墙	0.115	0.667
内墙	0.16	0.015 900 001
屋顶	1.442	0.012 7
地板	1.31	0.1016
单层玻璃	0.9	0.006
单层镀膜玻璃	0.9	0.006

用 EnergyPlus 软件进行能耗模拟,把模拟结果分为“每天”和“每小时”进行最后的结果输出,工作安排是做六休一。由于本文设计的建筑有着5个热区,在本文中只选择了南区作为研究对象,“每天”和“每小时”的能耗模拟结果如图4和图5所示,可以看出工作日的能耗高于休息日的能耗,在休息日不论是照明能耗还是设备能耗都是最低。本文基于 EnergyPlus 的模拟数据,把“每天”和“每小时”的模拟结果作为训练集以及测试集。

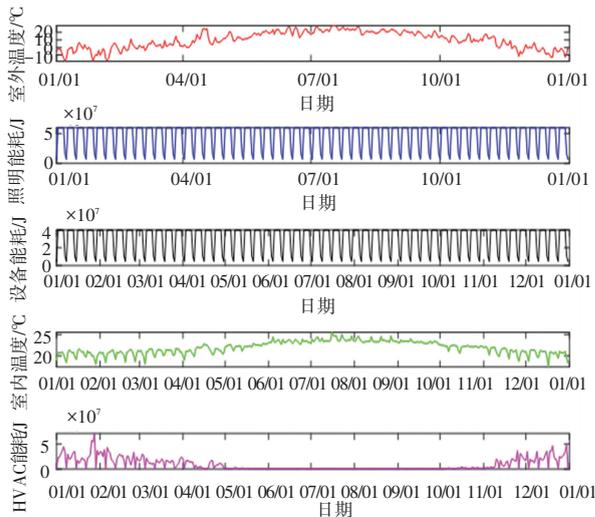


图4 “每天”的模拟结果

Fig. 4 Simulation results of “daily”

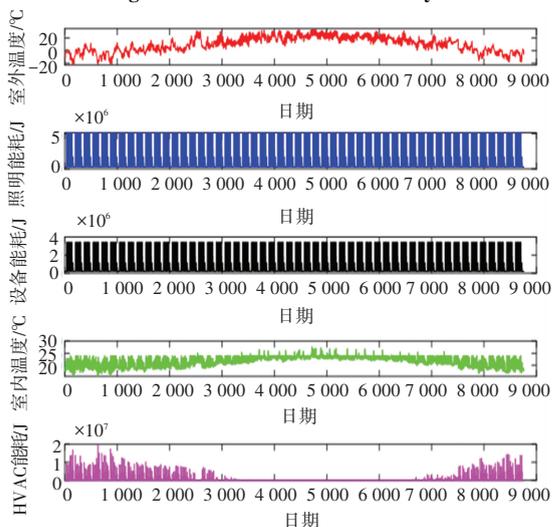


图5 “每小时”的模拟结果

Fig. 5 Simulation results of “hourly”

1.3 基于 LSTM 的预测流程

由于 LSTM 神经网络对于长时间序列数据有着十分出色的预测能力,因此本文采用 LSTM 神经网络来对能耗数据进行预测,具体的 LSTM 预测流程图如图6所示。



图6 LSTM 预测流程图

Fig. 6 LSTM prediction flow chart

2 预测模型建立

2.1 数据处理

(1)数据集划分。本文通过 EnergyPlus 软件进行一年的能耗模拟,模拟结果以两种输出方式输出,如图4和图5所示。第一种输出365天的数据,以前300天为训练集,后65天为测试集;第二种输出8760个小时的数据,以前8000个小时为训练集,后760个小时为测试集。

(2)数据归一化。由于样本数据之间的类型和数值大小各不相同,会导致绝对值相差很大。为了消除奇异样本数据导致的不良影响,会对数据进行归一化处理,将样本数据转换为 $[0, 1]$ 之间的数,归一化也可以加快训练网络的收敛性。归一化计算式(7):

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

其中, x 代表样本数据; x_{\min} 代表样本数据最小值; x_{\max} 代表样本数据最大值; x^* 代表归一化之后的值。

2.2 评价指标

为了确定 LSTM 训练网络预测的效果、精确度以及稳定性,本文中采用平均绝对误差 MAE,均方误差

MSE 和均方根误差 *RMSE* 作为预测模型的评价指标。*MAE* 体现预测结果和测试值之间的差值, 式(8); *MSE* 体现出预测结果的变化程度, 式(9); *RMSE* 则能更好的反映出预测结果的精度, 式(10)。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (8)$$

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

$$RMSE = \sqrt{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (10)$$

其中, y_i 代表 LSTM 预测模型的预测值, x_i 代表测试值。

2.3 参数选取

在 EnergyPlus 软件中选择输出数据为室外温度、室内温度、照明能耗、设备能耗以及 HVAC 能耗。其中, 照明能耗和设备能耗在工作时都会产生能耗, 会使得室内的温度上升, 从而对 HVAC 的能耗有一定程度上的影响。因此, 本文中主要使用室外温度、室内温度、照明能耗以及设备能耗作为输入来预测 HVAC 的能耗。

本文以室外温度、室内温度、照明能耗以及设备能耗作为 LSTM 神经网络的输入, HVAC 能耗作为 LSTM 神经网络的输出。以“每天”输出为主, 预先设置神经元数目为 128、256、512, 分别进行 5 次训

练, 得到不同的 *MSE* 值, 并取得平均值见表 4。神经元数目为 256 时 *MSE* 的值最小, 因此确定神经元数目为 256。按“每小时”输出的参数选取与按“每天”输出相同。Adam 具有适应稀疏梯度和缓解梯度震荡的优点, 本文中采用 Adam 求解器进行优化。在网络训练时, 在全连接层使用 Dropout 并设置为 0.2, 其目的是在每次训练批次中, 以一定的概率忽略一定数量的神经元, 这样防止在网络训练过程中出现过拟合的问题。

表 4 不同神经元数目 *MSE* 对比

Tab. 4 *MSE* comparison of different neuron numbers

神经元数目	<i>MSE</i> (* 5)
128	$4.99 * 10^6$
256	$4.74 * 10^6$
512	$5.63 * 10^6$

2.4 网络训练

本文中的 LSTM 网络设置为 5 个层, 分别有输入层、隐含层、全连接层、输出层以及回归层。基于不断的测试, 选定输入层的数目为 4, 输出层的数目为 1, 全连接层把 Dropout 设置为 0.2, 采用 Adam 求解器来进行优化, 训练次数设置为 250, 为了防止梯度爆炸, 梯度设置为 1, 初始学习率设置为 0.01, 经过 150 次训练后乘以 0.5 来降低学习率。“每天”LSTM 网络训练图如图 7 所示。

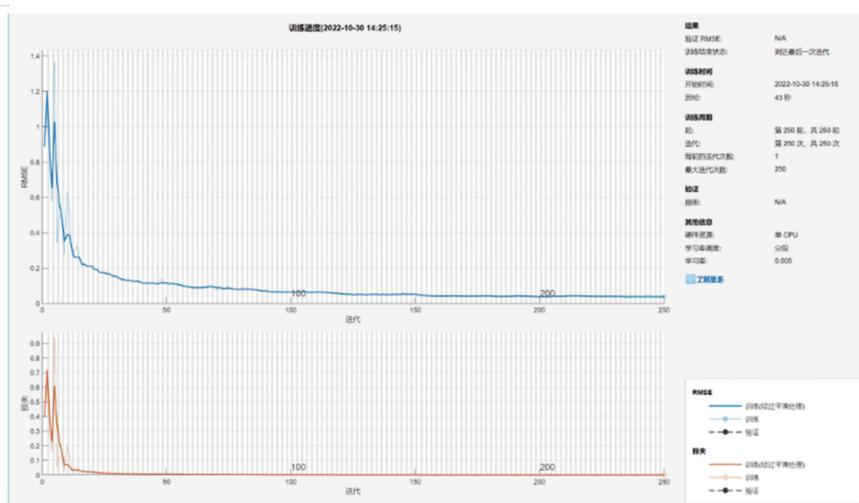


图 7 “每天”LSTM 网络训练图

Fig. 7 LSTM network training chart of “Daily”

由图 7 可知, 本次训练迭代次数为 250, 由于是按“每天”进行输出, 仅有 300 个训练集, 训练时间约为 43 s, 训练曲线都是随着迭代次数的增加而逐渐下降, *RMSE* 曲线在大约 170 次迭代之后趋于平缓, *RMSE* 的

值趋近 0.05, 而 *LOSS* 曲线则是在 100 次迭代之后趋于平缓, 且 *LOSS* 的值趋近 0。“每小时”LSTM 网络训练图与“每天”的类似, 差别在于训练集的增多会导致训练时间的延长以及 *RMSE* 的值趋近 0.1。

3 结果分析与对比

本文分别对“每天”和“每小时”两种输出进行预测,预测结果如图8和图9所示。由图8可以看出预测值的变化趋势和测试值的数据基本保持一致,而从图8(b)所示的预测误差图,预测的误差值在 $[-2.5 \times 10^7, 1.2 \times 10^7]$ 之间,其最大误差约为 -2.5×10^7 ,而最小误差值则趋近0;由图9可见,在预测曲线与测试值的变化趋势基本一致,拟合程度更好,而误差值也只在 $[-3.6 \times 10^6, 7.36 \times 10^6]$ 之间波动,不论是最大误差还是最小误差都优于前者。

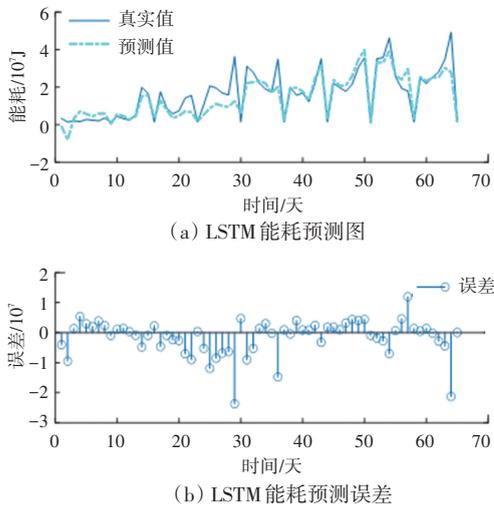


图8 LSTM“每天”测试结果

Fig. 8 LSTM test results of daily

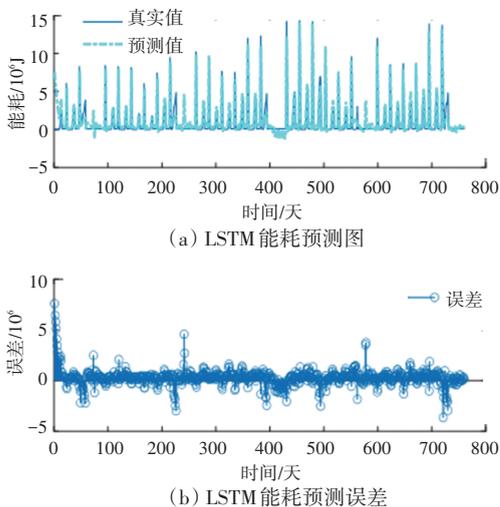


图9 LSTM“每小时”能耗预测图

Fig. 9 LSTM test results of hourly

为了验证训练模型的准确性,本文选择与BP神经网络模型进行对比,BP神经网络与训练网络有相同的结构,即输入层为4,隐含层节点数256,输出

层为1,迭代次数为250,学习率为0.01,最小误差设置为0.000 01,两种输出方式的预测结果图如图10和图11所示。对比相同训练集的BP模型和LSTM模型,由图10可知,BP网络预测值的变化趋势比LSTM网络预测值的变化趋势更为接近测试值,但在误差上则是LSTM网络模型占优;由图11可知,BP网络模型的预测值的变化曲线和测试值大部分是重合的,但在峰值前后会有一部分和测试值有细微的误差,误差范围在 $[-1.4 \times 10^7, 7.5 \times 10^7]$ 之间,而相对于LSTM模型的测试结果,不论是测试结果的变化趋势还是预测值与测试值之间的误差都是LSTM模型有着一定的优势。

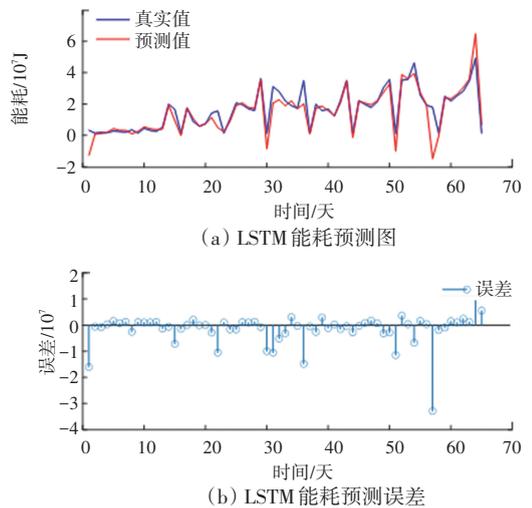


图10 BP“每天”测试结果

Fig. 10 BP test results of daily

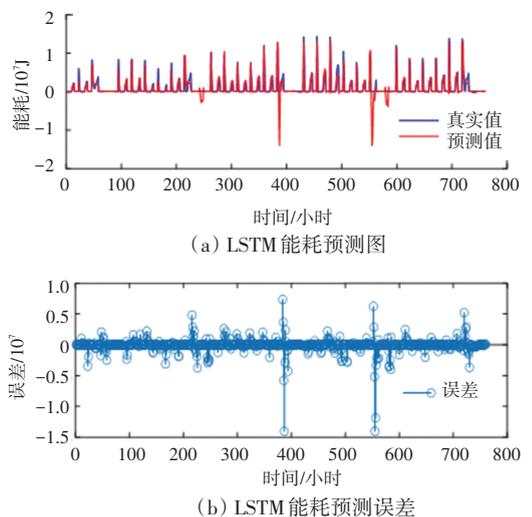


图11 BP“每小时”测试结果

Fig. 11 BP test results of hourly

同时,对LSTM模型和BP模型的性能评价指标进行计算,见表5。从表5中可以看出,LSTM模型

仅在“每天”测试结果的 *MAE* 指标比 BP 模型差,而其他的指标则 LSTM 模型都优于 BP 模型,说明 LSTM 模型对处理时间序列数据的效果比 BP 模型要好。

表5 不同模型的评价指标

Tab. 5 Evaluation indicators for different models

神经网络	LSTM		BP	
	“每天”	“每小时”	“每天”	“每小时”
<i>MAE</i>	4.11×10^6	0.43×10^6	3.36×10^6	0.44×10^6
<i>MSE</i>	24.3×10^{11}	0.47×10^{10}	392.20×10^{11}	15.75×10^{11}
<i>RMSE</i>	1.55×10^6	0.69×10^5	6.26×10^6	1.26×10^6

4 结束语

本文基于 EnergyPlus 软件进行能耗模拟得到的模拟数据,建立 LSTM 神经网络预测模型,并与 BP 神经网络预测模型进行对比分析,通过平均绝对误差 *MAE*,均方误差 *MSE* 和均方根误差 *RMSE* 这3个评价指标对模型进行评估。实验结果表明,LSTM 神经网络预测模型不论是 *MAE*、*MSE* 还是 *RMSE* 都是优于 BP 神经网络预测模型,可以更精确的预测能耗,能更好的反映出建筑能耗的变化趋势。

本文还有一些不足,LSTM 神经网络预测模型的输入仅考虑了室外温度、室内温度、照明能耗以及设备能耗这些因素,对于人员数目、风速、湿度以及光照等因素没有考虑,以后会把这些因素考虑进去。另外,在本文中也只分析了采暖能耗,没有对制冷能耗进行分析。在于对 LSTM 的优化上,本文只引入了 Adam 求解器进行了最简单的优化,后续会考虑用群体智能优化算法来对 LSTM 网络进行优化,提

高预测的准确度。

参考文献

- [1] SUN Yongjun, HUANG Gongsheng. Recent developments in HVAC system control and building demand management [J]. Current Sustainable/Renewable Energy Reports, 2017, 4(1): 15-21.
- [2] 中国建筑节能协会. 中国建筑能耗研究报告 2020 [J]. 建筑节能, 2021, 49(2): 1-6.
- [3] 张露,李永安,王德晔,等. 基于 FA-BP 组合模型的办公建筑能耗预测研究 [J]. 暖通空调, 2021, 51(10): 125-130.
- [4] KAWASHIMA M, DORGAN C E, MITCHELL J W. Optimizing system control with load prediction by neural networks for an ice-storage system [J]. ASHRAE Transactions, 1996, 102(1): 1169-1178.
- [5] 许馨尹,李红莲,杨柳等. 气候变化下的建筑能耗预测 [J]. 太阳能学报, 2018, 39(5): 1359-1366.
- [6] AMBER K P, ASLAM M W, MAHMOOD A, et al. Energy consumption forecasting for university sector buildings [J]. Energies, 2017, 154(10): 1579-1587.
- [7] 张卓渊. 一种基于生成对抗网络的建筑能耗多步预测方法 [J]. 电脑知识与技术, 2022, 18(23): 92-94, 110.
- [8] 井文强,关宏洁,罗薇,等. 基于改进 GWO-BP 的办公建筑能耗预测模型 [J]. 建筑节能(中英文), 2022, 50(8): 125-129, 149.
- [9] 曾国治,魏子清,岳宝,等. 基于 CNN-RNN 组合模型的办公建筑能耗预测 [J]. 上海交通大学学报, 2022, 56(9): 1256-1261.
- [10] 邵必林,史洋博,赵煜. 融合注意力机制与 LSTM 的建筑能耗预测模型研究 [J]. 软件导刊, 2021, 20(10): 61-67.
- [11] 洪丽娟. 基于 EnergyPlus 的冷水机组能耗评估工具 [J]. 制冷与空调, 2019, 19(8): 80-86.
- [12] LAI S, XU L, LIU K, et al. Recurrent convolutional neural networks for text classification [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2015: 2267-2273.
- [13] GRAVES A. Supervised sequence labelling with recurrent neural networks [M]. Berlin, Germany: Springer, 2008: 5-13.
- [14] 李锦锋,许勇. 基于 LBP 和小波纹理特征的室内室外场景分类算法 [J]. 中国图象图形学报, 2010, 15(5): 742-748.
- [15] LI L J, SU H, FEI-FEI L, et al. Object bank: A high-level image representation for scene classification & semantic feature sparsification [J]. Advances in neural information processing systems, 2010, 23: 1378-1386.
- [16] SADEGHI F, TAPPEN M F. Latent pyramidal regions for recognizing scenes [C]//European conference on computer vision. Springer, Berlin, Heidelberg, 2012: 228-241.
- [17] JUNEJA M, VEDALDI A, JAWAHAR C V, et al. Blocks that shout: Distinctive parts for scene classification [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2013: 923-930.
- [18] ZHOU B, LAPEDRIZA A, XIAO J, et al. Learning deep features for scene recognition using places database [J]. Advances in neural information processing systems, 2014: 487-495.
- [19] 胡旭科,尚建嘎,古富强,等. 融合 GPS 与 Wi-Fi 的室内外无缝定位原型系统研制 [J]. 小型微型计算机系统, 2014, 35(2): 428-432.
- [20] 鄢松,吴飞,朱海,等. 基于泛在信号融合的室内外场景鲁棒感知算法 [J]. 全球定位系统, 2020, 45(4): 63-71.
- [21] GAO H, GROVES P D. Environmental context detection for adaptive navigation using GNSS measurements from a smartphone [J]. Navigation: Journal of the Institute of Navigation, 2018, 65(1): 99-116.

(上接第36页)