

# 一种基于多元特征循环神经网络的建筑冷负荷软测量方法

刘贤稳 卢楚杰

(广东工业大学计算机学院 广东 广州 510006)

**摘要** 准确的冷负荷计算是采暖通风空调系统实时调控的基础,对建筑节能具有重大意义。软测量是实现冷负荷在线实时估计的方法,为提高软测量模型的预测性能,基于集成算法的思想提出多元特征循环神经网络,集成五种机器学习算法。为验证模型预测性能,在三个来自不同类型建筑的建筑能耗仿真数据集进行对比实验。实验结果表明,提出的模型对比其基模型预测性能大幅提升,与其他集成模型和时间序列预测模型相比评价指标上表现更好,并具有良好的预测稳定性。

**关键词** 冷负荷 软测量 集成学习 长短期记忆网络

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.10.016

## MULTI-FEATURE RECURRENT NEURAL NETWORK FOR BUILDING COOLING LOAD SOFT SENSING

Liu Xianwen Lu Chujie

(School of Computers, Guangdong University of Technology, Guangzhou 510006, Guangdong, China)

**Abstract** Real-time control on HVAC system, of great significance to building conservation, is based on accurate cooling load real-time calculation, which can be realized by soft sensing. In order to improve the prediction performance of soft sensing model, a multi-feature recurrent neural network based on Stacking algorithm is proposed, which integrates five machine learning algorithms. In order to verify the prediction performance of the model, comparative experiments were carried out on three building energy simulation data sets from different types of buildings. The experimental results show that the prediction performance of the proposed model is greatly improved compared with the base models, and the MAE and RMSE are the best compared with other integrated models and time series forecasting models, and have good prediction stability.

**Keywords** Cooling load Soft sensing Ensemble learning Long short-term memory

## 0 引言

建筑施工和运营的终端能耗占全球最终能源使用的36%<sup>[1]</sup>,其中采暖通风和空调(Heating Ventilation and Air Conditioning, HVAC)系统是建筑物所有能源服务中能耗最高的设备,约占建筑总能耗的50%~60%<sup>[2]</sup>,精确的冷负荷计算是 HVAC 系统优化运行和先进控制的基础<sup>[3]</sup>,对建筑节能具有重大意义。

冷负荷计算方法主要有三种:机理分析法、数据学习法和软测量方法<sup>[4]</sup>。其中软测量方法以可测量为

辅助变量,建立辅助变量与难以直接测量的冷负荷之间的数学模型,可以实现冷负荷的在线实时估计<sup>[5]</sup>,更适用于 HVAC 系统的在线实时调控。

软测量方法的核心是软测量建模,其可以分为机理分析建模和数据驱动建模<sup>[6]</sup>。对比机理分析建模,数据驱动建模不依赖于复杂的机理知识,建模难度更小,因而被广泛应用于软测量建模。数据驱动模型可以分为单一预测模型和集成预测模型,前者预测性能不稳定,对不同建筑预测或使用不同的比较标准时结果差异较大<sup>[7]</sup>;后者由一组经过单独训练的基模型组成,利用基模型的互补性,可以提供比单一预测模型更

稳定和准确的预测<sup>[8-10]</sup>。

为了进一步提高建筑冷负荷软测量的精度和稳定性,本文提出多元特征循环神经网络,在多种不同类型算法获得较为准确预测的基础上,引入长短期记忆网络(Long Short-Term Memory, LSTM)进行时间序列预测,捕捉数据的时间特征,从而能更好地拟合作为时间序列数据的建筑冷负荷数据,达到提高建筑冷负荷软测量精度的目的。实验结果表明,提出的模型对比其基模型性能大幅提升,并优于常用的集成模型和时间序列预测模型。

## 1 相关工作

预测模型最重要的两个模块是模型输入和预测算法。模型输入部分主要总结现有研究中使用的输入类型;预测算法部分简要介绍了三种常用集成算法以及目前用于时间序列预测最常用的长短期记忆网络模型。

### 1.1 模型输入选择

输入数据可以分为气象数据、占用数据、历史数据和类型信息。气象数据可以通过气象站获得,无论在模型的建立中还是以后模型的实际应用中收集都相对容易;占用数据指的是人类行为和建筑物的使用时间,对监控系统有很高的要求<sup>[11]</sup>,因此很少有研究直接将占用数据作为预测模型的输入数据;时间类型信息(例如时间、周几等)可以弥补由于缺少占用数据而丢失的信息<sup>[12]</sup>;历史数据也是一种流行的输入。大多数研究中的模型输入通常涉及这些类型中的两种或更多种类数据的组合,本文基于模型实用性的考虑,仅使用相对容易获取的可以实时测量的气象数据和可以提前确定的时间类型信息。

## 1.2 集成算法

### 1.2.1 Bagging

Bagging 是并行式集成算法的代表,通过自助采样法有放回地抽样,从同一组数据创建多个训练子集,然后使用多个训练子集并行训练多个各自独立的基学习器,最后根据不同任务选择投票法或平均法组合这些基学习器,因此 Bagging 可以大大降低模型的方差,提高模型的性能。

### 1.2.2 Boosting

Boosting 是串行式集成算法的代表,通过分步迭代的方式构建模型,先用初始训练集训练一个基学习器,根据基学习器的表现对训练样本分布进行调整,然后基于调整后的样本分布训练下一个基学习器,如此

迭代进行。迭代的每一步构建的基学习器都是为了弥补前面构建的基学习器的不足,从而训练出若干个有前后依赖关系的基学习器,最后对所有基学习器加权求和,从而改善模型高偏差的情况,得到更加准确的预测结果。

### 1.2.3 Stacking

Stacking 核心思想是并行训练一系列各自独立的不同类模型,首先通过训练得到多个基于不同算法的基模型,然后再将通过训练一个元模型来对基模型的输出结果进行融合。由于集成了不同的模型算法,可以从不同角度对数据进行分析,因此 Stacking 可以结合不同模型算法的优势,从而得到比基模型更好的预测性能和泛化能力<sup>[13]</sup>。

## 1.3 长短期记忆网络

LSTM 是一种特殊的循环神经网络,在普通循环神经网络的基础上,增加单元状态  $c$  用于存储长期状态,引入遗忘门、输入门和输出门三种门控状态,分别决定上一时刻单元状态  $c^{t-1}$  有多少保留到当前时刻单元状态  $c^t$ 、当前时刻输入  $x^t$  有多少保存到  $c^t$ ,以及  $c^t$  有多少输出到当前时刻隐藏状态(即输出值  $h^t$ ),从而获得较强的长期记忆能力,避免在处理长序列时出现梯度消失和梯度爆炸问题。LSTM 单元结构如图 1 所示。

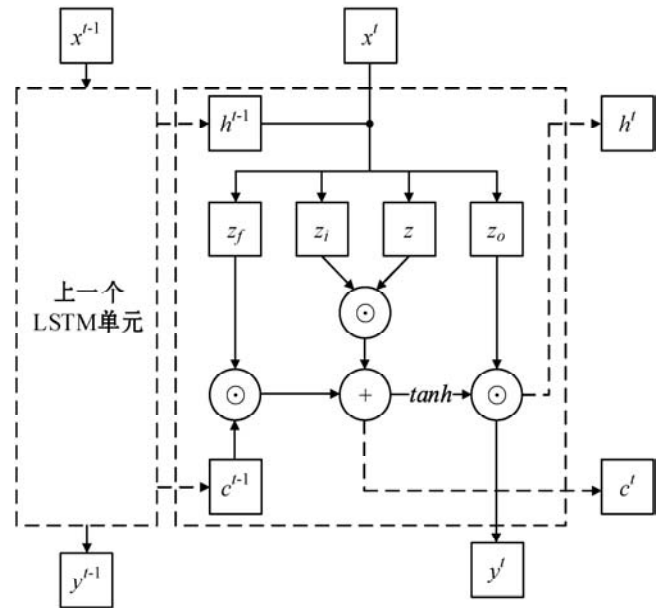


图 1 LSTM 单元结构图

LSTM 单元内计算式见式(1) - 式(6)。

$$z_f = \text{sigmoid}(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$z_i = \text{sigmoid}(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$z = \tanh(w \cdot [h_{t-1}, x_t] + b) \quad (3)$$

$$z_o = \text{sigmoid}(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$c_t = z_f \odot c_{t-1} + z_i \odot z \quad (5)$$

$$h_t = z_o \odot \tanh(c_t) \quad (6)$$

式中:  $x^t$ 、 $h^t$  和  $c^t$  分别表示  $t$  时刻的输入、输出和单元状态,  $z_f$ 、 $z_i$  和  $z_o$  分别表示遗忘门、输入门和输出门的门控状态,  $z$  表示单元状态更新值,  $w_f$ 、 $w_i$ 、 $w$  和  $w_o$  为权重系数,  $b_f$ 、 $b_i$ 、 $b$  和  $b_o$  为偏置,  $\text{sigmoid}()$ 、 $\text{tanh}()$  为激活函数,  $\odot$  表示 hadamard 乘积。

## 2 多元特征循环神经网络

本文结合 Stacking 集成算法和循环神经网络两者的优点, 提出了一种新的建筑冷负荷软测量模型。集成算法可以综合所有基模型的结果, 从而获得更稳定的预测结果, 在此基础上, 利用 LSTM 学习数据间的时序性, 进一步提高预测精度。本节将从模型框架、基模型的选择与构建、模型评价指标等方面对多元特征循环神经网络 (Multi-Feature Recurrent Neural Network, MFRNN) 进行介绍。

### 2.1 模型框架

MFRNN 模型具有两层结构, 如图 2 所示。第一层基模型层中每一个基模型的输出构成元特征, 作为第二层循环神经网络层的输入。

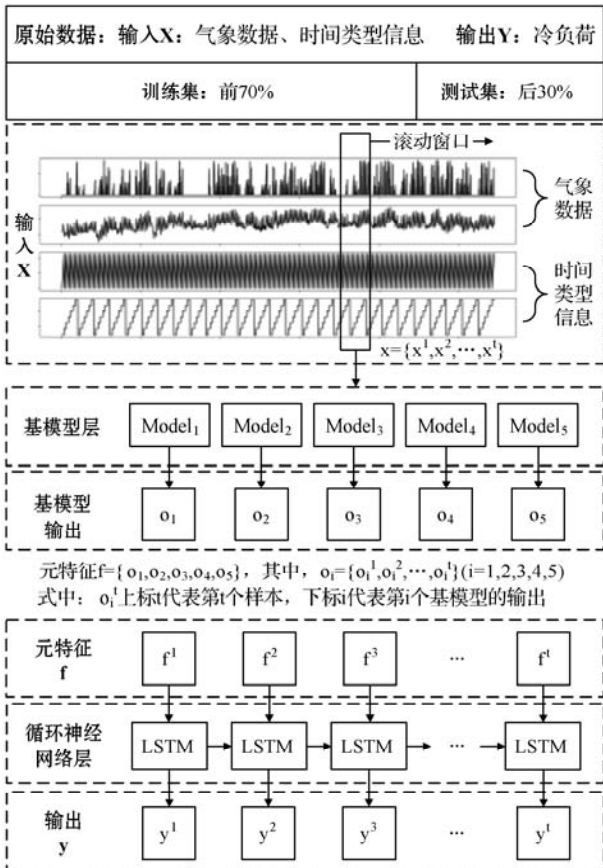


图2 基于多元特征循环神经网络的建筑冷负荷软测量流程  
具体算法见算法1。

#### 算法1 多元特征循环神经网络算法

输入: 建筑能耗数据集输入  $X$ ; 时间窗口大小  $t$ 。

输出: 每一个时间窗口的建筑冷负荷预测值  $y$ 。

设  $X$  的大小为  $\text{size}(X)$ , 将  $X$  划分为  $\text{size}(X)/t$  个大小为  $t$  的互不相交的时间窗口。

对于每一个时间窗口:

输入  $x = \{x^1, x^2, \dots, x^t\}$

For  $i = 1$  to 5

For  $t = 1$  to  $t$

$o_i^t = \text{Model}_i(x^t)$

end for

$o_i = \{o_i^1, o_i^2, \dots, o_i^t\}$

end for

$f = \{o_1, o_2, o_3, o_4, o_5\}$  //元特征由5个基模型输出构成

$y = \text{LSTM}(f)$  //LSTM 计算式见式(1) - 式(6)

### 2.2 基模型的选择

基模型的选择主要根据流行性和多样性原则, 所有选择的模型算法都广泛应用于解决复杂建模和预测问题且性能良好, 并在原理上差异较大, 最大化集成多样性从而使集成结果更准确和稳定。因此, 本研究选择了五种常用机器学习模型作为基模型, 这些算法模型在非线性处理能力, 模型架构和推理机制等各方面都有所不同。

(1) K 近邻算法 (K-Nearest Neighbor, KNN) 是最简单的机器学习算法之一, 理论成熟且训练方式高效, 可用于分类和回归任务, 在回归任务中通过找出给定测试样本基于距离度量 (例如欧氏距离和曼哈顿距离) 的  $K$  个最近训练样本, 然后基于这些样本的平均值进行预测。

(2) 支持向量回归 (Support Vector Regression, SVR) 是支持向量机的重要应用分支, 通过核函数将数据映射到高维特征空间, 在高维空间找到一个超平面使所有训练样本距离该平面最近, 该平面即回归平面。

(3) 多层感知机 (Multi-Layer Perception, MLP) 是一种前向结构的人工神经网络, 包含输入层、输出层和若干个隐含层, 每一层包含若干人工神经元, 层与层之间全连接, 即上一层的所有神经元有向连接下一层的所有神经元, 训练过程使用反向传播算法不断调整神经元之间的连接权重从而模拟出输入与输出的映射关系。

(4) 随机森林 (Random Forest, RF) 是 Bagging 算法中最著名的算法, 在 Bagging 集成样本扰动 (自助采样) 的基础上, 引入了随机属性扰动, 即对特征进行了选择, 使得基学习器之间的差异度增加, 从而使最终集成的学习器泛化性能进一步提升。

(5) 极端梯度提升 (Extreme Gradient Boosting,

XGBoosting) 是 Boosting 算法中的一种,在传统 Boosting 算法的基础上,对代价函数进行二阶泰勒展开,使梯度收敛更快更准确,并在代价函数中加入正则化项,控制模型的复杂度,防止过拟合,同时支持多线程并行查找每个特征的最佳分割点,极大提升训练速度。

### 2.3 基模型的构建

为了避免过拟合,使用五重交叉验证训练每一个基模型 $i(i = 1, 2, 3, 4, 5)$ ,如图 3 所示,将训练集分为五个互不相交的集合,每次使用其余四个集合训练模型用以预测第  $n$  个集合的结果( $n = 1, 2, 3, 4, 5$ ),并得到一个训练后的基模型 $i$ ,最后得到五个集合的预测结果和五个训练后的基模型 $i$ ,将五个集合的预测结果拼接起来得到一个与原训练集长度相等的集合,作为基模型 $i$ 在训练集上的输出,五个基模型 $i$ 对测试集的预测结果平均值作为基模型 $i$ 在测试集上的输出。

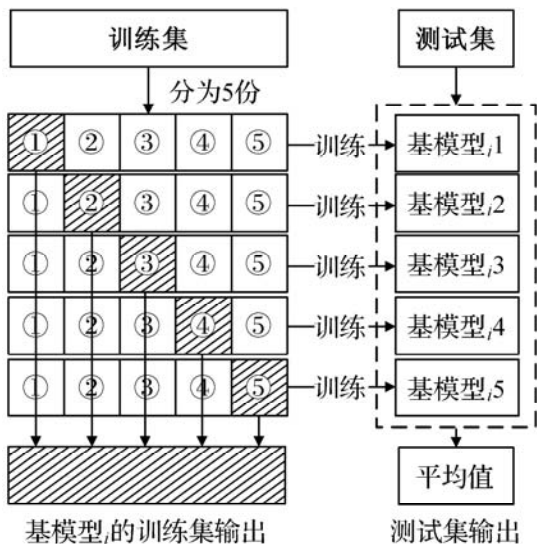


图 3 基模型的构建

### 2.4 模型评价指标

建筑冷负荷软测量的评价指标通常有三种方式:平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Squared Error, RMSE)、均方根误差变异系数(Coefficient of Variation of the Root Mean Square Error, CVRMSE)。其计算式如式(7) - 式(9)所示。

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

$$E_{CVRMS} = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{\bar{y}} \times 100\% \quad (9)$$

式中: $n$  为样本数量, $y_i$  和  $\hat{y}_i$  分别代表第  $i$  个样本的建筑冷负荷真实值和预测值, $\bar{y}$  代表所有样本建筑冷负

荷的平均值。

这些指标每一个都有不同的侧重点。MAE 可以直观地显示预测值和真实值之间的平均误差;RMSE 代表预测值和真实值之间的样本标准差,与 MAE 相比放大了误差,用于识别较大的误差;CVRMSE 规范化了预测误差,并可以提供更方便比较的无单位度量,比较不同模型之间的精度差异。MAE、RMSE、CVRMSE 三个指标值越小,模型性能越好。

## 3 实验与结果分析

### 3.1 实验环境与数据

实验计算环境为 Python 3.7.6, TensorFlow 2.3.1 深度学习框架, Microsoft Windows 7 操作系统, 8 GB 内存, Intel Core i7-5500U CPU @ 2.40 GHz 处理器。

本实验采用了分别来自三座不同类型建筑物的三个建筑能耗仿真数据集,选取其中的气象数据包括太阳辐射和室外温度、时间类型信息包括当前时间的小时和星期几作为模型输入,选取建筑冷负荷数据作为模型输出。数据采集步长为 1 次/10min,记录了一年中从 4 月 9 日到 10 月 14 日共 27 216 组数据。取前 19 152 组数据(前 70%)作为训练集,后 8 064 组数据(后 30%)作为测试集。表 1 是对三座建筑物冷负荷数据的描述性统计。图 4 显示了三座建筑物的冷负荷变化曲线。

表 1 建筑冷负荷数据统计

数据集	建筑类型	建筑物每十分钟冷负荷/kWh			
		平均值	最小值	最大值	标准差
数据集 1	医院	16.44	0	131.21	18.41
数据集 2	宾馆	11.87	0	36.27	6.14
数据集 3	办公室	10.98	0	269.73	18.37




图 4 建筑冷负荷数据概况

### 3.2 数据预处理

为了缩短模型训练时间,提高模型预测精度,防止模型梯度爆炸,对数据集的每一项数据进行标准化处理,即应用标准化公式使得新数据集的每一项数据方差为 1,均值为 0,将不同量级的数据统一转化为同一量级。标准化公式如式(10)所示。

$$X = \frac{x - \mu}{\sigma} \quad (10)$$

式中: $X$  为标准化后的新数据, $x$  为原始数据, $\mu$  和  $\sigma$  分别为原始数据的均值和标准差。

### 3.3 超参数优化

本实验使用网格搜索对所有基模型(KNN,SVR,MLP,RF,XGBoosting)中需要人为调整的超参数进行调优,遍历所有可能参数的组合,并使用五折交叉验证评估各组合的表现。对于 LSTM 中的超参数隐含层单元数  $units$  和时间窗口大小  $t$ ,保持基模型中的超参数不变,对  $units \in \{16, 32, 64, 128, 256\}$ ,  $t \in \{72, 144, 288\}$  进行网格搜索,根据多次实验结果进行评估。模型最终的超参数如表 2 所示。

表 2 网格搜索优化后的超参数选择

模型	超参数	数据集 1	数据集 2	数据集 3
KNN	n_neighbors	60	55	19
SVR	C	1	0.3	0.2
	gamma	'auto'	0.06	0.5
MLP	hidden_layer_sizes	(100,)	(8,4,)	(64,4,)
	activation	'relu'	'tanh'	'relu'
RF	n_estimators	13	6	3
	max_depth	9	8	10
	min_samples_split	5	6	4
	min_samples_leaf	6	4	6
XGBoosting	learning_rate	0.09	0.12	0.2
	max_depth	5	2	7
	n_estimators	85	140	55
LSTM	units	32	64	128
	t	144	144	144

### 3.4 实验结果分析

使用五种基模型在三个建筑能耗仿真数据集上建立预测模型,预测结果见表 3。

表 3 基模型预测结果对比(20 次实验平均值)

模型	数据集 1		数据集 2		数据集 3	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
KNN	3.663 3	7.657 6	2.499 3	3.266 4	2.593 6	7.169 4
SVR	5.040 2	8.612 5	<b>2.263 1</b>	<b>2.867 8</b>	4.617 3	8.464 8
MLP	3.271 0	<b>6.048 9</b>	2.316 3	2.921 0	2.907 4	5.879 3
RF	<b>2.982 6</b>	6.374 9	2.424 7	3.177 4	<b>1.928 3</b>	5.695 9
XGBoosting	3.005 9	6.107 9	2.354 4	3.056 6	2.101 2	<b>5.451 4</b>

可以看出,预测精度最高的基模型对于数据集 1 是 MLP(RMSE 最小)和 RF(MAE 最小),对于数据集 2 是 SVR,对于数据集 3 是 RF(MAE 最小)和 XGBoosting(RMSE 最小),可见基模型对不同数据集的预测性能并不稳定,并且对同一数据集使用不同模型评价指标也可能会得到不一样的结果。

为了提高预测精度和稳定性,本文基于 Stacking 集成算法的思想,提出了 MFRNN 模型。为了评估该模型的性能,将其预测结果与使用相同基模型的 Stacking 集成模型、LSTM 模型在测试集上的预测结果进行对比,如表 4 所示。

表 4 不同预测模型预测结果对比(20 次实验平均值)

数据集	评价指标	模型		
		Stacking	LSTM	MFRNN
数据集 1	MAE	2.717 2	2.543 1	<b>2.312 1</b>
	RMSE	5.670 6	4.765 4	<b>3.831 3</b>
	CVRMSE	0.311 7	0.261 9	<b>0.210 6</b>
数据集 2	MAE	2.110 1	2.191 9	<b>1.986 9</b>
	RMSE	2.664 0	2.770 2	<b>2.588 4</b>
	CVRMSE	0.208 4	0.216 7	<b>0.202 5</b>
数据集 3	MAE	1.896 9	1.921 0	<b>1.570 6</b>
	RMSE	5.166 6	4.678 7	<b>3.448 9</b>
	CVRMSE	0.408 5	0.369 9	<b>0.272 7</b>

从表 3、表 4 数据分析可得:MFRNN 模型对比基模型预测精度有了大幅度提升,MFRNN 模型在三个数据集上的预测结果(无论是 MAE 还是 RMSE)均优于 Stacking 集成模型和 LSTM 模型,并且 MFRNN 模型在三个数据集上的 CVRMSE 均小于 0.3,满足 CVRMSE 小于 30% 的要求。

图 5 是 Stacking 集成模型、LSTM 模型和 MFRNN 模型 20 次实验结果的箱形图展示。可以看出 MFRNN 模型的预测精度远高于 Stacking 集成模型,对比 LSTM 模型,MFRNN 模型不仅预测精度更高,在多次实验中的预测结果表现也更稳定。

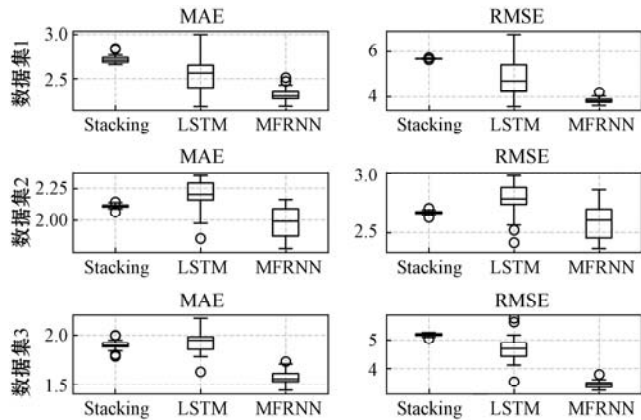


图 5 不同预测模型预测结果箱形图

## 4 结 语

本文提出了一种基于多元特征循环神经网络的建筑冷负荷软测量方法,结合 Stacking 集成算法和 LSTM 的优点,通过集成学习算法集成五种不同类型的机器学习算法(KNN, SVR, MLP, RF, XGBoosting),学习输入数据与建筑冷负荷之间的关系,再通过 LSTM 学习序列数据的时间特征,使用该模型在三个不同建筑类型的建筑能耗仿真数据集进行实验预测。结果表明, MFRNN 模型在其基模型的基础上预测精度明显提升,不仅优于 Stacking 集成模型和 LSTM 模型,并且在多次实验中均能得到相对稳定的预测结果。

收集更多不同类型建筑的能耗数据来验证多元特征循环神经网络的通用性,并引入全局优化算法、注意力机制等技术进一步提高模型的预测性能可能是下一步的研究工作。

## 参 考 文 献

[1] International Energy Agency. Global status report for buildings and construction 2019[R]. Paris: IEA, 2019.

[2] 清华大学节能中心. 中国建筑节能年度发展研究报告[M]. 北京: 中国建筑工业出版社, 2015.

[3] Fan C L, Ding Y F, Liao Y D. Analysis of hourly cooling load prediction accuracy with data-mining approaches on different training time scales[J]. Sustainable Cities and Society, 2019, 51: 101717.

[4] 刘廷章, 邵敏, 李占培, 等. 建筑空间负荷预测方法[J]. 暖通空调, 2016, 46(10): 45-54.

[5] Li Z P, Liu T Z. Improved particle filter based soft sensing of room cooling load[J]. Energy & Buildings, 2017, 142: 56-61.

[6] 李占培. 建筑空间冷负荷实时软测量无监督建模方法研究[D]. 上海: 上海大学, 2017.

[7] Zeng A, Liu S, Yu Y. Comparative study of data driven methods in building electricity use prediction[J]. Energy & Buildings, 2019, 194: 289-300.

[8] Wang Z Y, Wang Y R, Srinivasan R S. A novel ensemble learning approach to support building energy use prediction[J]. Energy & Buildings, 2018, 159: 109-122.

[9] Fan C, Xiao F, Wang S W. Development of prediction models for next-day building energy consumption and peak power demand using data mining techniques[J]. Applied Energy, 2014, 127: 1-10.

[10] Wang R, Lu S L, Feng W. A novel improved model for building energy consumption prediction based on model integration[J]. Applied Energy, 2020, 262: 114561.

[11] 卢楚杰, 李思慧. 多传感器融合的建筑入住率感知模型研究[J]. 计算机应用与软件, 2021, 38(1): 58-62.

[12] Chae Y T, Horesh R, Hwang Y D, et al. Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings[J]. Energy & Buildings, 2016, 111: 184-194.

[13] 王辉, 李昌刚. Stacking 集成学习方法在销售预测中的应用[J]. 计算机应用与软件, 2020, 37(8): 85-90.

## (上接第 103 页)

[6] 郑涛, 马龙, 李博文. 基于馈线终端装置信息畸变校正的有源配电网故障区段定位[J]. 电网技术, 2021, 45(10): 3926-3935.

[7] 黄佳乐, 杨冠鲁. 配电网故障区间定位的改进矩阵算法[J]. 电力系统保护与控制, 2014, 42(11): 41-45.

[8] 汤安迪, 韩统, 徐登武, 等. 基于混沌麻雀搜索算法的无人机航迹规划方法[J]. 计算机应用, 2021, 41(7): 2128-2136.

[9] 欧阳城添, 朱东林. 融合 K-means 的多策略改进麻雀搜索算法研究[J]. 电光与控制, 2021, 28(12): 11-16.

[10] 汤安迪, 韩统, 徐登武等. 混沌精英哈里斯鹰优化算法[J]. 计算机应用, 2021, 41(8): 2265-2272.

[11] 马一鸣, 石志东, 赵康, 等. 基于改进哈里斯鹰优化算法的 TDOA 定位[J]. 计算机工程, 2020, 46(12): 179-184.

[12] 王巍璋, 王淳, 敖鑫. 基于果蝇优化算法的配电网故障定位[J]. 电力系统保护与控制, 2019, 47(18): 108-114.

[13] 郭小红, 赵雪松, 朱永利, 等. 基于改进果蝇优化算法的雷电定位研究[J]. 电测与仪表, 2016, 53(16): 5-10.

[14] 魏聪聪, 邓祥力, 贾声昊, 等. 基于多源数据及多维故障诊断空间的快速智能电网故障诊断方案[J]. 电测与仪表, 2022, 59(10): 145-153.

[15] 徐航, 张达敏, 王依柔, 等. 混合策略改进鲸鱼优化算法[J]. 计算机工程与设计, 2020, 41(12): 3397-3404.

[16] 刘煜, 王俊江, 焦青, 等. 基于量子行为粒子群算法的含分布式电源的配电网故障定位[J]. 智慧电力, 2020, 48(8): 51-55.

[17] 赵瑞锋, 郭文鑫, 王彬, 等. 基于群灰狼优化算法的双馈感电机最优控制[J]. 电力系统保护与控制, 2020, 48(14): 150-158.

[18] 甄永琦, 蒋伟. 改进灰狼算法在配电网故障定位中的应用[J]. 计算机应用与软件, 2020, 37(11): 200-205.