

DOI: 10.19650/j.cnki.cjsi.J2006875

基于 CFD 和 LightGBM 算法的建筑室内温度 全局预测模型*

石欣¹, 田文彬^{1,2}, 冷正立¹, 卢灏¹

(1. 重庆大学自动化学院 重庆 400044; 2. 中国科学院深圳先进技术研究院
广东省机器人与智能系统重点实验室 深圳 518055)

摘要:温度控制对建筑节能意义重大,室内温度准确预测是建筑温度精确控制的前提。本文提出一种基于计算流体力学(CFD)和 LightGBM 算法的建筑室内全局温度预测模型实现对同一时间全局温度模拟和全局时间序列温度变化预测。基于空间建筑结构、传感器精度范围和实际温度控制范围简化的 CFD 简化模型满足精度要求同时解决了数据冗余的问题,更具实践性。在此基础上通过 LightGBM 和 LSTM 算法模拟全局区域温度空间序列变化规律,采用 LightGBM 算法预测温度时间序列变化实现对室内温度全局预测。试验采用某地区烟草储存库全年建筑运行数据和室内外温度监测数据,构建室内全局温度预测模型,通过实际测量温度数据实验验证,建筑全局 5 h 温度分布预测准确系数为 0.955 4,60 h 温度范围预测准确系数为 0.994 0,对比 ANN, BP, LSTM 算法,本文模型平均准确系数提高 0.022 4~0.014 7。

关键词:建筑节能;建筑温度;全局温度预测;计算流体力学;LightGBM

中图分类号: TH765; TP19 **文献标识码:** A **国家标准学科分类代码:** 510.40

Global prediction model for indoor temperature based on CFD and LightGBM algorithm

Shi Xin¹, TianWenbin^{1,2}, Leng Zhengli¹, Lu Hao¹

(1. School of Automation, Chongqing University, Chongqing 400044, China; 2. Guangdong Provincial Key Lab of
Robotics and Intelligent System, Shenzhen Institutes of Advanced Technology, Shenzhen 518055, China)

Abstract: Temperature control is significant to building energy conservation, and the accurate prediction of indoor temperature is the prerequisite for precise control of building temperature. Proposes a global indoor temperature prediction model based on computational fluid dynamics (CFD) and LightGBM algorithms to realize global temperature simulation and global temperature change prediction over time. The simplified CFD model is based on the space building structure, sensor accuracy range, and actual temperature control range, which can meet the accuracy requirements and solve data redundancy, making it more practical. On this basis, the LightGBM algorithm and LSTM algorithm are used to simulate the global temperature spatial sequence change law. To be specific, the LightGBM algorithm is employed to predict the temperature-time sequence changes to realize the global prediction of indoor temperature. The experiment utilizes the annual building operation data and indoor and outdoor temperature monitoring data of a tobacco storage warehouse to construct an indoor global temperature prediction model. Experimental results of the practical measured temperature data show that the temperature distribution accuracy coefficient of 5 h global forecast is 0.955 4, and the temperature range accuracy coefficient of 60 h global predict is 0.994 0. Compared with the ANN, BP, and LSTM algorithms, the average accuracy coefficient of the proposed model is improved by 0.022 4~0.014 7.

Keywords: building energy efficiency; building temperature; global temperature prediction; computational fluid dynamics; LightGBM

收稿日期:2020-09-06 Received Date: 2020-09-06

* 基金项目:国家自然科学基金(61473050)项目资助

0 引言

温度监控在建筑节能领域意义重大。在建筑能耗中^[1],空调系统是主要耗能设备约占总能耗的55%,建筑大部分能耗用于维持建筑室内温度在设定范围内波动。尤其对于生产制造厂、大型公共场所和食品制造储存等功能性建筑,温度分布情况直接影响生产、效益、储存等建筑功能性^[2-5],在住宅、医院、学校等居住性建筑,温度分布直接影响使用者舒适性^[6-8]。在满足建筑功能性和舒适性的基础上实现建筑节能是温度控制的根本目的^[9]。

传统温度监控方法主要包括热成像技术和传感器技术,热成像技术^[10]可实现实时高精度温度监测但监控范围有限。传感器技术更加灵活,通过建筑中部署的温度传感器^[11]实时采集温度数据,反馈当前温度分布情况,但传感器节点有限,部署位置特定,感知范围有限,不能做到全局监控。此外,由于温度的滞后性和多参数的耦合性,实时监控的方法不能提前感知温度分布,不适用于提前控制。

模型预测控制(model prediction control, MPC)^[12]方法通过温度预测模型采集某时刻的建筑温度分布数据,预测下一时刻温度分布,并根据预测结果控制供暖通风与空调(heating ventilation air conditioning, HVAC)系统做功,从而控制建筑温度。温度预测模型可以解决现实中大量复杂非线性高精度的控制问题,更适用于要求对温度精确控制的建筑。当前,温度预测方法主要包括:

1) 白盒模型,建立于对物理现象精确数学描述。工程性方法是使用建筑热环境模拟工具进行建模,如ANSYS Fluent、Star-CCM+、CFX、scSTREAM等。模拟工具内嵌的物理模型借助计算流体动力学(computational fluid dynamics, CFD)技术预测建筑温度,如预测烟草储存库温度分布^[13],预测自然通风下建筑的室内空气温度^[14],预测蘑菇室内的温度分布^[15]。采用CFD模型进行建模,虽然完成高精度建模,但信息量大、计算速度慢、灵活性低,无法适用于控制器的设计和分析等问题,不能完成对工业建筑的提前控制。

2) 黑盒模型,建立于经验数据的规律描述。数据驱动方法是近年来研究最多的新方法,基于数学的机器学习方法和深度学习方法为建筑温度预测提供了建模新思路,不同于上述方法建模过程的繁琐,该方法简化了建模过程,只需要将目标参数数据放入模型进行训练就能得到精度较高的模型,同时模糊了各因素间的耦合作用,运算快准确性高,提高了模型精确度,广泛运用于多因素影响下的复杂建筑和大型建筑场景,

如非线性自回归神经网络来进行短期和中期预测建筑室内温度^[16],基于分层关注门控循环单元模型的节能建筑室内温度预测框架^[17],基于神经网络补偿的人工气候箱温湿度模糊控制^[18]。但该方法要采集大量数据进行模型训练,一般采集温度传感器的数据进行训练,采集时间周期长,数据不易获得,监控范围有限,数据不具备全局代表性。

本文建立的建筑室内温度全局预测模型结合CFD和数据驱动方法,基于建筑结构、建筑温度控制范围和传感器精度范围,以空间位置 and 对应温度为特征聚类简化CFD模型。根据实际采集温度,运用LightGBM和长短期记忆(long short term memory, LSTM)算法模拟全局空间序列温度变化规律,预测全局时间序列温度,实现少量节点数据模拟和预测全局温度。

1 基于CFD的全局区域仿真模型

建筑温度随建筑空气流动,随建筑能量波动,是建筑气体流动和传热传质现象具体表征,建筑温度仿真模型是气流模型和传热传质模型的集成。基于不同的实际情况采用不同的假设、区域划分方法、原理、求解方法和结果,可将建筑仿真模型分为3类,其具体特征如下所示^[19]:

1) 多区域模型:按照建筑结构将房间或结构划分为一个整体,并假设其中的参数如压力、温度和密度等都是完全均匀的。

2) CFD模型:将建筑划分为若干个小细胞(cells),细胞的数量比多区域模型和区域模型的数量要多得多,并针对每个细胞单进行复杂的质量、动量和能量计算。

3) 区域模型:多区域和CFD模型的中间选择,划分区域比多区域模型范围小但比CFD模型区域大。

这3种模型各有特点适用于不同的场景要求,多区域模型由于计算简便更适用于大型复杂建筑或温度控制范围较宽的建筑,而CFD模型适用于精确控制建筑或小型建筑,区域模型是两种模型的中间选择适用范围更宽。随着计算机及电子信息技术的发展,计算机计算能力得到提升,学者们更倾向于使用CFD模型进行仿真,建模过程如图1所示。

对于建筑温度预测,CFD仿真方法能保证仿真数据的准确性,但却存在数据冗余的问题,无法适用于实时控制。相对而言,区域模型大大减少了网格数目和数据量,但该模型没有明确规定网格划分数目方法,精度计算方法和具体评判标准,不能直接套用于建筑温度预测仿真。因此,在满足模型精度要求同时简化CFD模型是最佳选择,如表1所示。

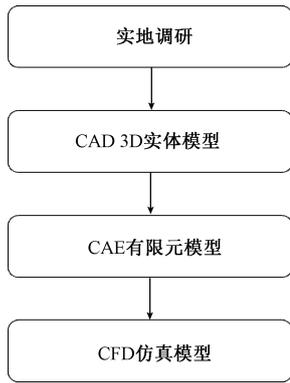


图 1 CFD 建模过程

Fig. 1 CFD modeling process

表 1 4 类建筑仿真模型特点

Table 1 Characteristics of four building simulation models

建筑能量 气流模型	网格 大小	建模 难度	模型 准确性	网格划分规则
多区域模型	大	低	低	建筑结构
区域模型	中	中	中	建筑结构 仿真精度要求
CFD 模型	小	高	高	仿真精度要求 建筑结构
CFD 简化模型	中	高	高	温度控制要求 温度传感器范围

本文提出的 CFD 简化模型采用面对对象的思想建模,首先在建筑有限元模型的基础上 CFD 模型并进行仿真,将仿真数据与建筑温度控制范围和温度传感器精度范围对应,从而计算簇的空间的范围大小。随后根据建筑结构特性划分建筑网格,同时 CFD 仿真数据也划分为区域模型仿真数据,具体建模过程如下:

1) CFD 模型仿真,把建筑划分为有限个细胞形成有限元模型,并根据实测建筑信息进行仿真,得到高精度的建筑温度分布数据。

2) 区域模型划分,通过特征降维方式划分建筑为若干相同的长方体(簇),由于 CFD 模型的细胞体积远远小于区域模型的簇,所以在空间里的细胞也归属于不同簇,如图 2 所示。

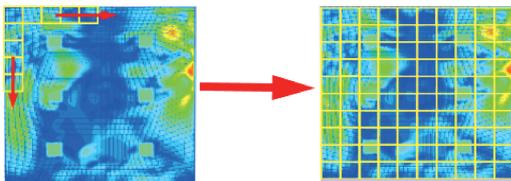


图 2 CFD 模型的细胞聚类

Fig. 2 Cells cluster of CFD model

3) 区域模型模拟,建筑划分为 N 簇 $R_j(x_j, y_j, z_j, t_j)$, 簇的中心点代表簇的位置,长方体的范围代表该簇的位置范围,所有细胞温度的平均值代表簇的温度,所有细胞温度的范围代表簇的温度范围。每个簇内有 P 个细胞 $C_i(x_i, y_i, z_i, t_i)$ 。

簇内平均温度范围:

$$T_{mm} = \frac{1}{P} \sum_{i=0}^P (\max(t_i) - \min(t_i)) \quad (1)$$

簇的温度标准偏差:

$$T_s = \frac{1}{N} \sum_{j=0}^N \frac{1}{P} \left(\sum_{i=0}^P (t_i - \bar{t}_i) \right) \quad (2)$$

簇的温度范围标准偏差:

$$T_{ms} = \frac{1}{N} \sqrt{\sum_{j=0}^N (T_{mm} - \overline{T_{mm}})^2} \quad (3)$$

4) 模拟效果分析,簇内平均温度范围、簇的温度标准偏差和簇的温度范围标准偏差越小,模型划分效果越好。簇内平均温度范围应当小于温度传感器精度范围,这代表可用传感器采集值直接代表簇的温度。由于建筑需要空调、通风口、除机等制冷(热)设备来控制温度,必然存在能量交换处温度范围大于温度传感器精度范围的不合格簇。通过分析不合格簇的位置分布,查看其是否处于建筑控制区域来判定模型划分效果。

对比传统的建模方法,CFD 简化方法从建筑实际温度预测控制需求出发,结合空间位置聚类方法和面对对象建模思想有效地根据建筑结构、建筑温度控制范围和温度传感器精度范围划分 CFD 模型有限元细胞。该模型在保证精度同时精简数据,有具体的划分规则和评判标准,更具备实践性。

2 温度序列预测算法

当前,关于建筑温度的研究主要包括温度监测、预测和控制,这些研究重点关注温度在时域的规律变化,关于建筑温度空间变化的研究很少。事实上,大多建筑的能量输入(电能),能量输出(热能)长期保持稳定,即能量稳态。此时,建筑温度分布长期稳定且随空间位置变化也呈现规律变化,因此,本文重点探讨建筑处于能量稳态时,室内温度随空间随时间分布规律。为实现对建筑全局模拟,本文结合 LightGBM 和 LSTM 算法,对简化后的全局区域模型仿真数据进行建筑温度分布规则学习,实现少量节点模拟全局模型节点。

当前流行序列预测算法主要包括:ANN, NARX, LSTM, BP 等,本文对从建筑类型、模型输入参数、时间间隔、预测时长和准确性等运用效果总结如表 2。将上述算法运用于温度时域预测和空间规律模拟,对比发现

LSTM 算法相较于其他算法在温度规律模拟和预测方面 更有优势。

表 2 时间序列预测算法运用对比

Table 2 Comparison of the application of time series forecasting algorithms

算法	文献	建筑类型	模型输入参数	数据间隔	预测时长	模型准确性
神经网络模型 (Artificial Neural Network model, ANN)	文献[20]	旧建筑	室内外温湿度 太阳辐射	5 min	2 h	$t=2\text{ h}$, 准确 $t=4\text{ h}$, 不准确
非线性自回归模型 (nonlinear Autoregressive Exogenous model, NARX)	文献[21]	图书馆	空调及通风系统 室内外环境数据	5 min	气候周期	$t=14\text{ d}$, 准确 $t>14\text{ d}$, 不准确
LSTM 模型	文献[22]	办公楼	室内温度实测数据	5 min	5 min/30 min	对比其他算法, LSTM 表现更好
反向传播模型 (Back Propagation model, BP)	文献[23]	仓库	室内外温湿度	10 min	6 h/24 h/48 h	$t=6\text{ h}$, $MES=0.07$ $t=24\text{ h}$, $MES=0.16$ $t=48\text{ h}$, $MES=0.22$

LSTM 算法本质上是循环神经网络 (recurrent neural networks, RNN) 的特殊模型, 用来处理 RNN 训练过程中梯度消失和梯度爆炸的问题, 形成了记忆数据和结果数据的独立传输机制, 如图 3 所示, 常见的 LSTM 细胞结构由一个存储单元、一个输入门、一个输出门和一个遗忘门组成。

1) 遗忘门: 神经元有选择性的忘记过去的无用信息。

$$f = \sigma(W_{xf}x^{(t)} + W_{hf}h^{(t-1)} + b_f) \quad (4)$$

2) 输入门: 管理当前神经元中输入的新信息。

$$i = \sigma(W_{xi}x^{(t)} + W_{hi}h^{(t-1)} + b_i) \quad (5)$$

3) 输出门: 对现时记忆的选择性输出。

$$o = \sigma(W_{xo}x^{(t)} + W_{ho}h^{(t-1)} + b_o) \quad (6)$$

$$h^{(t)} = o^{(t)} \odot \tanh(c^{(t)})$$

4) 神经元神经更新。

$$c^{(t)} = f^{(t)} \odot c^{(t-1)} + i^{(t)} \odot \tanh(W_{xc}x^{(t)} + W_{hc}h^{(t-1)} + b_c) \quad (7)$$

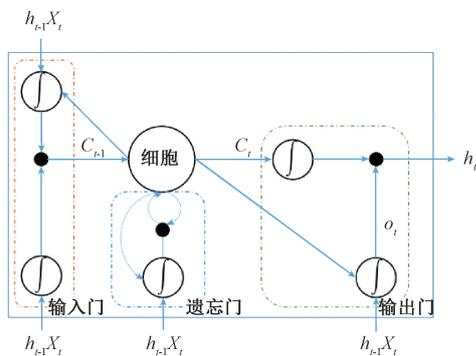


图 3 LSTM 细胞结构

Fig. 3 LSTM cell structure

这 3 个门控机制控制了细胞传输状态, 对于建筑空间序列和时间序列这类较长的序列上相较于 RNN

表现更好, 所需要的训练数据量较少, 准确性高, 泛化性好。

相较上述算法, 算法和算法等新型 Boosting 算法在时间序列预测效果更好。XGBOOST 和 LightGBM 都源于梯度提升框架 (gradient boosting decision tree, GBDT), 是最近流行的适用于大规模数据集的并行集成算法, 具有多核并行运算、正则化提升、自定义目标函数等特点, 被广泛运用于各领域。

LightGBM 算法是一种改进的梯度提升决策树框架, 通过 M 棵弱回归树线性组合为强回归树。它在 XGBoost 的基础上改进了直方图算法和带深度限制的叶子生长策略, 提高了训练效率, 实现低内存使用, 有更高的准确率, 尤其适用于建筑全局温度时间序列这种大规模数据处理。

模型的准确性可由各种统计指标来验证, 本模型使用的是 MAE, MSE, R^2 来分析模型。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - s_i)^2}{\sum_{i=1}^n \left[y_i - \frac{1}{n} \sum_{i=1}^n y_i \right]^2} \quad (8)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - s_i|}{n} \quad (9)$$

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

其中, v_i 为测试温度值, s_i 为模拟温度值, R^2 趋于 1, MAE 和 MSE 趋于 0 代表模型性能好。实际建筑中由温度传感器感知室内温度, 在温度传感器精度误差范围 Re 内的测试误差可以被忽略, 即 $|y_i - s_i| < Re$ 时认为该簇模拟正确。在划分的 N 个簇中的 M 个簇的 $|y_i - s_i| > Re$, 则实际模型全局误差系数为:

$$GE = \frac{M}{N} \tag{11}$$

3 全局区域温度预测模型

全局区域温度预测不仅要考虑温度在空间序列的规律变化也要考虑随时间序列的规律变化。为实现对全局区域温度预测,实验将分为对同一时间点全局区域温度模拟和对不同时间点的全局区域温度预测。

3.1 全局空间序列温度模拟

建筑的固有属性如窗墙比,窗地比,建筑材料的热导率等维持建筑热量固定扩散。建筑中的温度分布取决于建筑结构、室外环境、冷热源分布、空调系统、空气流动等因素,在建筑中温度分布规律变化。当建筑保持能量输入输出不变时,由于空气传热快,随气流波动的特性,建筑温度快速变化并长期处于能量稳态,即建筑与外部能量交换稳定,此时,温度分布基本保持稳定,温度分布规律能被模拟。

基于 CFD 的全局区域仿真模型将 CFD 模型简化为若干个簇,建筑中部署的传感器根据空间位置对应到不同的簇,基本可以适用于建筑控制。虽然建筑中部署的传感器往往具备建筑温度代表性,能反映建筑整体温度变化,所以传感器可作为观测点实时反馈建筑温度。在实际建筑中由于存放货物、作业区域、人行通道等传感器不方便部署原因,传感器不能随意地部署在每一个簇的中心位置,部署的传感器节点是有限的,部署的位置是特定的,传感器的感知范围不能完全覆盖建筑,传感器数据无法满足建筑温度全局模拟,只能作为输入点,通过数据驱动模型推断整体温度分布。

当建筑处于能量稳态时,温度变化幅度小,不同簇的温度相互影响,温度在空间中的 X,Y,Z 3 个方向形成一定的排布规律。将建筑划分的簇按 X,Y,Z 3 个方向顺序依次排序如图 4 所示,其温度规律也在按空间位置重新排布。将 LSTM 算法运用于温度空间序列排布模拟,算法通过学习记忆前面序列的规律。

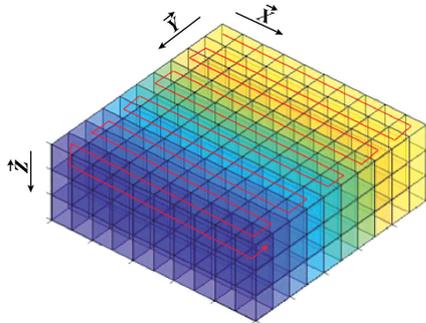


图 4 空间序列分布

Fig. 4 Spatial sequence distribution

在实际建筑中,温度传感器要求反馈建筑温度整体分布,往往分散在建筑中,没有空间序列上的直接关系,不能作为前序列直接输入到 LSTM 算法中。因此,首先建立前序列模拟模型,观测点作为模型输入,通过 LightGBM 算法按顺序依次模拟出前序列,如图 5 所示。再建立后序列模拟模型,将前序列输入到模型中,使用 LSTM 算法对建筑温度空间序列进行模拟,如图 6 所示。按照步长 K 依次模拟 K+1, K+2...N,从而实现同一时间点的全局区域温度模拟。

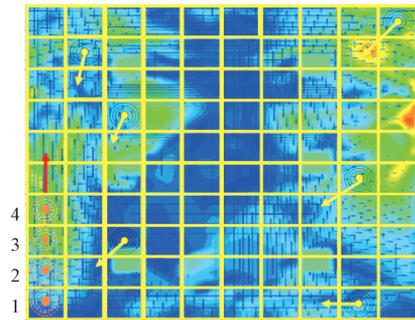


图 5 前序列模拟

Fig. 5 Pre-sequence simulation

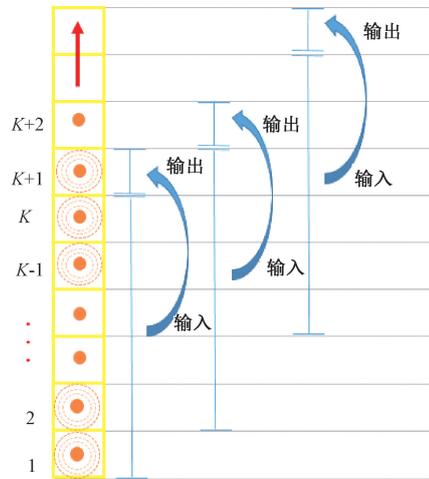


图 6 空间序列模拟模型

Fig. 6 Simulation model of space sequence

3.2 全局区域温度预测

建筑温度准确预测是建筑环境精确控制的前提。当前大多数温度预测研究只针对代表性温度预测,如室内平均温度、室外温度、室内温度范围和传感器采集温度(观测点温度)等,但全局温度预测更有实际意义。尤其能量稳态下的室内温度受多因素影响波动,并随时间规律变化至稳态,温度传感器部署在建筑中按时间间隔采集数据反映此变化。将在同一时间点上的温度分布数据

视为一帧数据,不同帧数据反映全局区域温度在时域的变化。不同于预测建筑平均温度或局部区域温度,全局区域温度预测要求模拟完整的一帧数据。

对比现有温度预测算法和运用,模型输入一般为室内外温度及其他相关气候影响因素。对于全局区域温度预测,模型的输入为 L 帧室内外温湿度数据,空气流动风速,和室外光照。使用性能较好的 LightGBM 算法进行全局温度预测建模。每帧数据有若干簇,以簇的空间位置为特征,簇的温度为标签进行预测。类似于空间序列模拟,用前 L 帧数据按照步长 L 依次预测 $L+1, L+2 \dots$ 帧的温度分布,并将预测的数据加入到模型中进行预测,进行下一步预测。

4 模型运用

4.1 实验背景

用于实验的建筑位于重庆某地区,规划用途为烟草存储仓库。建筑长 48.2 m,宽 34.4 m,高 2.8 m,为大空间复杂建筑,其平面图如图 7 所示。

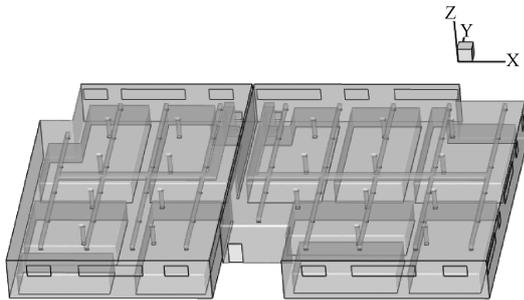


图 7 建筑平面图
Fig. 7 Building layout

建筑温度变化对烟草存储的质量有显著影响。因此部署传感器监控建筑温度十分必要,要求室内温度长期控制在 $26 \pm 3^\circ\text{C}$ 之内。该建筑长期在 11 个固定区域堆放烟草,本模型控制区域为无货物堆积部分,传感器基本部署在货物旁,用于反馈整体建筑温度变化,部署位置如图 8 所示。

本实验选用的温度传感器为 SHT15 型,它是一种集成了温度测量和校准数字信号输出的复合单片机传感器,具有抗干扰能力强、响应速度快等优点,具体参数见表 3。

由于烟草储存相对封闭但不绝对密闭的特性,室内温度也受到室外温度影响,如图 9 所示。该建筑空调系统长期根据该月气候按特定功率正常工作,所以该建筑长期处于能量稳态。

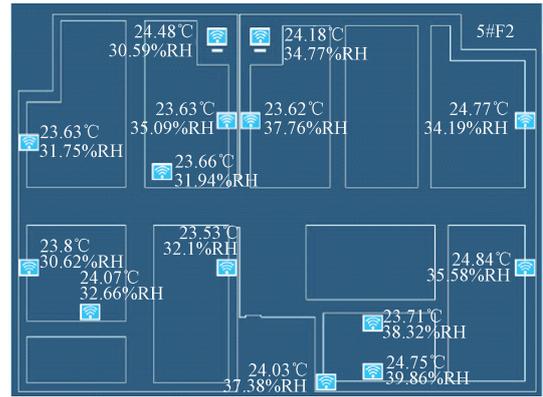


图 8 传感器部署
Fig. 8 Sensor deployment

表 3 温度传感器参数

Table 3 Temperature sensor parameters

参数	范围	精度	分辨率
温度/ $^\circ\text{C}$	-40~123.8	± 0.3	0.01

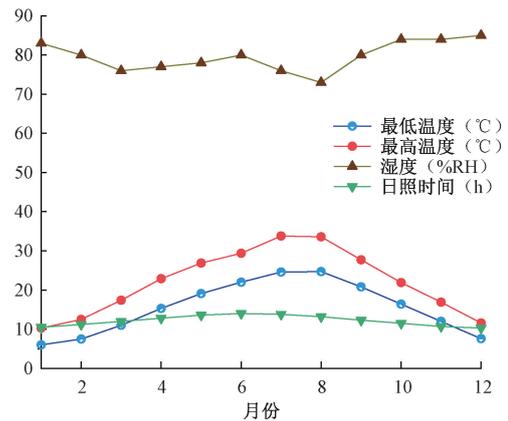


图 9 黔江地区年均气候参数

Fig. 9 Average annual climate parameters in Qianjiang area

4.2 全局区域模型构建

根据实地采集建筑信息建立建筑的 CFD 模型如图 10 所示。将 CFD 模型按 $0.8 \sim 2.2 \text{ m}^3$ 大小体积,依照等边长和建筑比例的方式划分。

依据 T_{min} , T_s 和 T_{ms} 对模型划分方式进行实验,实验结果如图 11 所示。随着体积减小,不合格簇比例减少,不合格点基本分布在空调出口、门、窗等能量交换处。

根据传感器精度范围,簇的温度范围应 $< 0.6^\circ\text{C}$,所有簇内温度偏差和簇的温度范围标准偏差越小越好,因此选择按体积为 0.8 m^3 ,划分方式为建筑比例划分建筑为 3 371 个簇,对比 CFD 模型很大程度上减少网格数目,避免数据冗余,划分效果如图 12 所示,对比效果如表 4 所示。

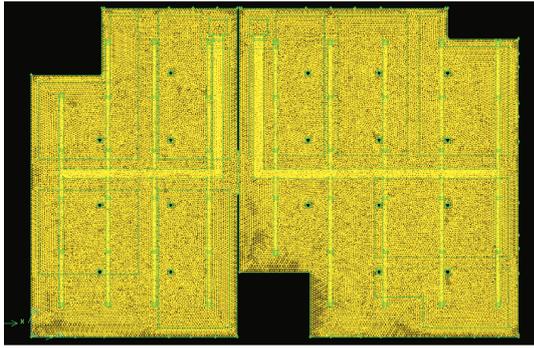


图 10 建筑 CFD 模型

Fig. 10 Building CFD model

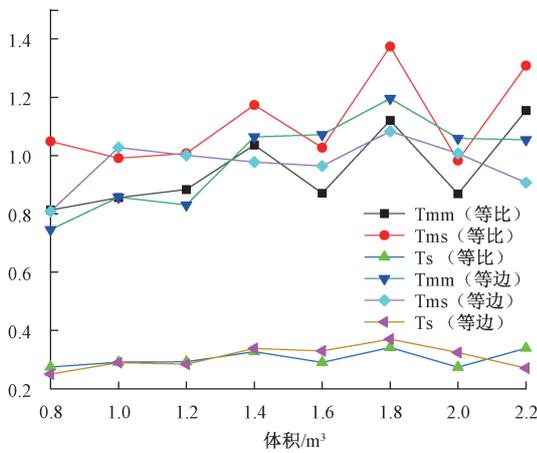


图 11 CFD 模型划分试验对比图

Fig. 11 CFD model division test comparison chart

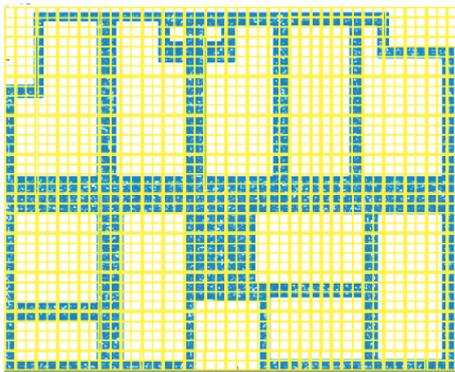


图 12 全局区域模型

Fig. 12 Global zone model

表 4 划分效果对比

Table 4 Comparison of division effects

模型	网格大小/m ³	网格数目	网格形状	精度
CFD 模型	0.246 2~9.515	1 619 305	结构化六面体	高
CFD 简化模型	800	3 371	长方体	高

4.3 全局区域空间序列模拟模型

根据 2019 年每月特定时刻的室内外环境进行温度仿真,得到每个月建筑温度分布仿真数据,并进行区域划分排序,得到温度分布规律如图 13 所示。12 个月温度分布规律相似但存在差别,采用分月预测的方法,分别建立每个月的全局温度预测模型。将每月区域仿真数据按 8:2:2 划分为训练集,测试集和验证集。在仿真数据中找到建筑中部署的 14 个传感器位置,选取其中 8 个点标记为输入点,作为空间序列模拟模型输入变量,剩下的 6 个传感器位置用作待模拟的测试点,并交叉验证模型。

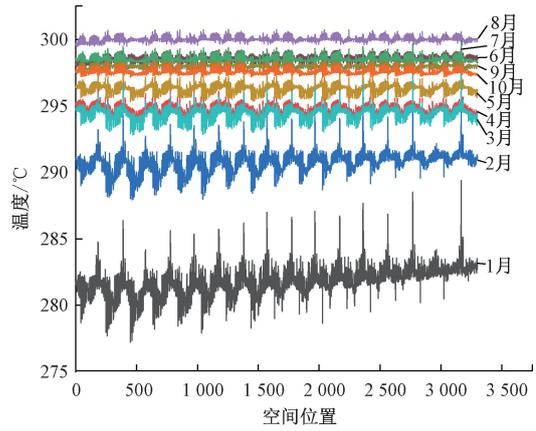


图 13 温度分布规律

Fig. 13 Temperature distribution pattern

由于初始模型输入点较少,只能通过将模拟值加入模型中进行模拟的方式扩充数据集。但是随着越来越多的模拟值加入模型进行预测,必定导致误差增加。所以本实验交叉使用上述两种算法扩展数据集。

按照如图 14 流程交叉重复上述步骤,将 LSTM 预测的后序列和初始感知节点一起输入到 LIGHTGBM 模型进行前序列模拟,将 LIGHTGBM 模型模拟的前序列输入到 LSTM 模型模拟节点,直到按顺序模拟完所有的节点。

首先建立 LIGHTGBM 模型进行前序列模拟。初始模型输入为部署了传感器的 8 个节点,模型输出为前序列温度数据,为确定模型的输入节点数和输出节点数(前序列)的比值进行试验,实验结果如表 5 所示。

通过 LIGHTGBM 模型推断出的前序列输入到 LSTM 模型模拟后序列,因为 LSTM 算法需要通过学习输入前序列分布规律从而预测后序列,所以前序列输入的点越多,后序列预测的准确率越高,为确定输入模型的前序列与后序列的比值进行试验,试验结果如表 6 所示。

对比试验结果发现 $R_{f \rightarrow l}$ 的值为 0.1 时 LIGHTGBM 和 LSTM 模型准确性最高,选择 0.1 作为两个模型的输入输出比。依照模拟顺序构建了 41 个 LIGHTGBM 模型和 36 个 LSTM 模型,预测顺序如图 15 所示。

表5 R_{f-t} 与 LightGBM 模型准确性

Table 5 Relationship of LIGHTGBM accuracy and R_{f-t}

R_{f-t}	输出数目 输入数目	0.1	0.2	0.3	0.5	1
GE		0.995	0.96	0.93	0.87	0.85

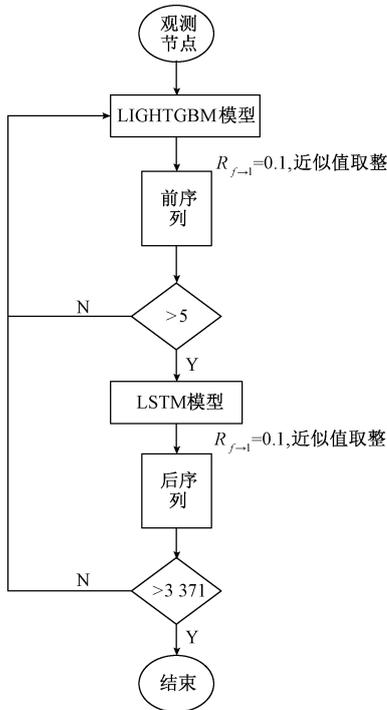


图14 空间序列模拟流程

Fig. 14 Flow of space sequence simulation

表6 R_{f-t} 与 LSTM 模型准确性

Table 6 Relationship of LSTM accuracy and R_{f-t}

R_{f-t}	GE	MSE	R^2	MAE
1	0.430 8	0.361 5	0.000 3	0.454 7
0.9	0.605 6	0.529 8	0	0.489 7
0.6	0.783 5	0.313 5	0.450 0	0.512 0
0.3	0.894 2	0.125 2	0.620 0	0.123 5
0.1	0.942 7	0.111 0	0.930 0	0.190 0

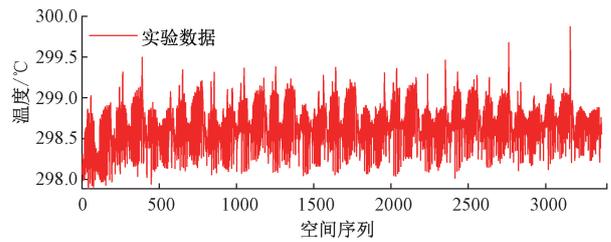
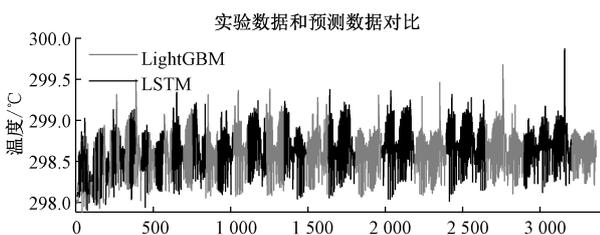


图15 空间序列模拟顺序

Fig. 15 Simulation order of spatial sequence

按照此方法,根据 2018~2019 年传感器采集 120 组温度数据测试 12 个模型,结果如表 7 所示。

表7 空间序列模拟

Table 7 Space sequence simulation

月份	MAE	MSE	R^2	GE
1	0.087 9	0.023 9	0.931 0	0.971 8
2	0.067 6	0.014 0	0.896 6	0.984 3
3	0.104 8	0.029 3	0.943 6	0.952 5
4	0.039 5	0.004 2	0.925 6	0.996 4
5	0.062 8	0.008 0	0.844 2	0.994 4
6	0.077 9	0.012 1	0.794 8	0.981 0
7	0.091 7	0.015 6	0.813 7	0.975 4
8	0.082 3	0.012 9	0.811 0	0.982 5
9	0.085 2	0.016 3	0.759 0	0.966 2
10	0.094 1	0.022 5	0.844 3	0.954 3
11	0.051 2	0.010 4	0.822 2	0.988 7
12	0.087 2	0.014 0	0.846 0	0.976 6
平均值	0.077 7	0.015 3	0.852 7	0.977 0

实验结果表明 MAE、MSE 和 R^2 的平均值分别为 0.077 7, 0.015 3 和 0.852 7, 模型具有较好的精度,但模型拟合效果一般。但温度传感器本身存在精度误差,所以在传感器的精度范围内模型准确率较高,平均准确率为 0.977 0,所以建筑内约有 77 个簇不能准确模拟。将传感器的精度范围扩大到 $\pm 1^\circ\text{C}$, 准确率提高到 100%, 而该建筑的控制范围为 $\pm 3^\circ\text{C}$, 少量点在较小的范围内不能准确模拟不影响建筑能量控制。

4.4 全局区域时间序列预测模型

在实验建筑中部署的 14 个传感器每隔 5 分钟采集一次数据,一次数据收集的 8 个感知节点作为观测节点模拟空间序列模型一帧数据。同时,室外温度传感器、室内外湿度传感器、光照强度传感器和风速传感器记录建筑气候干扰因素。将全局温度模拟数据(3 371 个温度节点)和室内外气候数据(5 个能量节点)输入到建立的

LIGHTGBM 模型中进行模型训练和验证,将实际感知节点模拟的数据代入预测模型进行试验。

1) 单帧预测

基于 1 帧数据分别建立 LIGHTGBM 模型预测 5 min、10 min、30 min、1 h、3 h 和 5 h 后建筑温度分布。将实际传感器采集数据对比对应预测节点预测数据,节点实际误差系数为:

$$T_y = \left| \frac{T_{real} - T_{pred}}{T_{real}} \right| \quad (12)$$

式中: T_{real} 为实际数据; T_{pred} 为预测数据。按传感器精度范围要求所有 $T_r < 0.01$,按建筑温度范围要求所有 $T_r < 0.1$ 。建立的模型参数如表 8 所示,预测结果如表 9 所示。

表 8 LIGHTGBM 模型参数

Table 8 LIGHTGBM model parameters

参数	5 min、10 min、30 min、1 h、3 h、5h
boosting_type	gbdt
Objective	binary
Metric	rmse
num_leaves	15、20、15、25、20、20
learning_rate	0.001、0.01、0.01、0.1、0.1、0.1
feature_fraction	0.8
bagging_fraction	0.8
bagging_freq	5、5、7、5、6、7

表 9 短时间序列预测

Table 9 Short time series forecast

预测时间	MAE	MSE	R ²	GE	T _r
5 min	0.073 9	0.014 5	0.955 3	0.985 9	<0.000 01
10 min	0.102 8	0.019 8	0.940 7	0.979 9	<0.000 53
30 min	0.117 4	0.024 8	0.929 3	0.969 8	<0.000 72
1 h	0.100 0	0.022 2	0.959 8	0.965 5	<0.004 26
3 h	0.101 5	0.022 5	0.957 1	0.960 0	<0.007 52
5 h	0.117 6	0.030 4	0.941 6	0.955 4	<0.007 99

采用单帧预测方法能准确预测 5 h 之内的温度,若按建筑的温度控制范围评估准确率,即 $|y_i - s_i| > 3^\circ\text{C}$,则节点温度范围准确系数

$$GET = \frac{M_T}{N} \quad (13)$$

其中, M_T 为超出温度控制范围的簇的数目,按照单帧预测方法进行试验,结果如表 10 所示。

单帧数据可以评估 60 h 内建筑全局是否超出温度控制范围,指导建筑制热(冷)设备控制,从而实现建筑节能。

表 10 长时间序列预测

Table 10 Long-term series prediction

预测时间	GE	GET
5 h	0.950 4	1
10 h	0.820 8	1
30 h	0.698 6	1
60 h	0.535 2	0.994 0

2) 多帧预测

基于多帧数据分别预测 30 min、1 h、5 h、10 h、15 h、20 h、25 h 和 30 h 后建筑温度分布,试验结果如表 11 所示。

表 11 多帧数据预测

Table 11 Multi-frame data prediction

预测时间(3 帧)	30 min	1 h	5 h	10 h
MAE	0.126 5	0.137 3	0.129 7	0.125 4
MSE	0.023 7	0.027 7	0.025 7	0.024 6
R ²	0.932 9	0.921 8	0.926 1	0.921 5
GE	0.972 4	0.965 3	0.960 6	0.940 2
T _y	<0.000 5	<0.000 7	<0.000 7	<0.002 5
预测时间(6 帧)	15 h	20 h	25 h	30 h
MAE	0.116 4	0.125 4	0.176 4	0.177 1
MSE	0.024 4	0.025 4	0.048 8	0.048 9
R ²	0.954 0	0.909 2	0.907 4	0.906 0
GE	0.900 4	0.848 1	0.841 9	0.840 0
T _y	<0.003 7	<0.005 2	<0.005 1	<0.008 5

建筑温度传感器采集的数据可以储存在云端,使用多帧数据实现更长时间的准确预测。试验结果显示多帧数据在短时间内预测效果和单帧数据预测效果相等,但在长时间预测表现得更好。

为了证明 LightGBM 算法的准确性和实时性,从模型准确性和运算速度两个方对比 LightGBM 算法与其他时间序列算法。将建筑全局温度分布数据作为模型输入,分别按单帧预测和多帧预测使用 LSTM^[22], ANN^[20], BP^[23] 时间序列算法预测 5、30 和 60 h 后的建筑温度分布,模型参数如表 12 所示,结果如表 13 所示。

表 12 ANN, BP 和 LSTM 模型参数

Table 12 Parameters of ANN, BP and LSTM

隐藏层	神经元	学习率	迭代次数	传递函数
2	3 376, 3 371	0.01	3 000	ReLU

表13 预测算法对比

Table 13 Comparison of prediction algorithms

算法(单帧预测)	GE/5 h	GE/30 h	GE/60 h
LSTM	0.942 4	0.593 2	0.452 4
ANN	0.927 5	0.515 4	0.246 2
BP	0.933 6	0.552 3	0.425 2
LightGBM	0.955 4	0.628 6	0.535 2
算法(3帧预测)	GE/5 h	GE/30 h	GE/60 h
LSTM	0.948 2	0.596 3	0.242 4
ANN	0.942 5	0.502 1	0.251 4
BP	0.949 5	0.548 6	0.351 4
LightGBM	0.960 6	0.692 3	0.453 2

试验结果表明,LightGBM 比其他算法在单帧和多帧预测的效果要好,单帧平均准确系数提高 0.022 4,多帧平均准确系数提高 0.014 7。不同算法训练时长差别较大,所对比的 3 种算法需要较长时间训练才能达到较好的预测效果,LightGBM 更适合建筑全局温度预测建模。

5 结 论

温度预测是建筑温度控制的难点问题,本文提出的建筑室内温度全局预测模型,从建筑节能角度出发,考虑能量稳态下的全局建筑温度预测。通过采集建筑信息和设备运行监测数据构建建筑 CFD 模型,并基于建筑结构特性、建筑温度控制要求和温度传感器精度简化 CFD 模型,制定了该区域模型的划分标准和评判标准,具备工程实践性。采用 LightGBM 和 LSTM 算法模拟建筑全局温度分布规律,预测全局温度时间序列,实现少量节点预测建筑全局温度。通过实测数据构建训练模型,对比实际数据验证模型在短期预测和中期预测的准确性,分析该模型在单帧预测和多帧预测下短时间和长时间的性能,该模型在实验场景下能准确预测 5 h 建筑全局温度分布,准确系数为 0.955 4,节点实际误差系数小于 0.007 99,可以预判 60 h 室内温度整体波动,范围准确系数为 0.994。对比 LSTM,ANN,BP 等经典建筑温度预测算法,单帧平均准确系数提高 0.022 4,多帧平均准确系数提高 0.014 7。

参考文献

- [1] IEA. Renewables information 2019[J]. Climate Change 2013-The Physical Science Basis, 2019,DOI: 10.1787/fa89fd56-en.
- [2] OLIVEIRA A, CASTRO P M, AMARO A L, et al. Optimization of temperature, relative humidity and storage time before and after packaging of baby spinach leaves using response surface methodology [J]. Food and Bioprocess Technology, 2016, 9(12): 2070-2079.
- [3] LI Y, JIA W, ZHANG C H, et al. Fluctuated low temperature combined with high-humidity thawing to reduce physicochemical quality deterioration of beef[J]. Food and Bioprocess Technology, 2014, 7 (12): 3370-3380.
- [4] NGUYEN VAN LONG N, VASSEUR V, COROLLER L, et al. Temperature, water activity and pH during conidia production affect the physiological state and germination time of Penicillium species[J]. International Journal of Food Microbiology, 2017, 241:151-160.
- [5] SEEL W, DERICHS J, LIPSKI A. Increased biomass production by mesophilic food-associated bacteria through lowering the growth temperature from 30°C to 10°C [J]. Applied and Environmental Microbiology, 2016, 82(13): 3754-3764.
- [6] FORCADA N, GANGOLELLS M, CASALS M, et al. Summer thermal comfort in nursing homes in the Mediterranean climate[J]. Energy and Buildings, 2020, 229,DOI: 10.1016/j.enbuild.2020.110442.
- [7] LOU R, HALLINAN K P, HUANG K, et al. Smart wifi thermostat-enabled thermal comfort control in residences[J]. Sustainability (Switzerland), 2020, 12 (5), DOI: 10.3390/su12051919.
- [8] HUANG K T, HWANG R L. Parametric study on energy and thermal performance of school buildings with natural ventilation, hybrid ventilation and air conditioning[J]. Indoor and Built Environment (Special Issue), 2016, 25(7):1148-1162.
- [9] JOHARI F, PERONATO G, SADEGHIAN P, et al. Urban building energy modeling: State of the art and future prospects[J]. Renewable and Sustainable Energy Reviews, 2020, 128, DOI: 10.1016/j.rser.2020.109902.
- [10] 张志强,王萍,于旭东,等.高精度红外热成像测温技术研究[J].仪器仪表学报,2020,41(5):10-18.
ZHANG ZH Q, WANG P, YU X D, et al. Study on high accuracy temperature measurement technology of infrared thermal imager [J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 10-18.
- [11] 毕付,张东亮,鹿利单,等.基于全保偏光纤的反射式双折射干涉温度传感器[J].仪器仪表学报,2020,41(8):120-128.
BI F, ZHANG D L, LU L D, et al. Reflective birefringent interference temperature sensor based on polarization maintaining optical fiber [J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 120-128.

- [12] DRGONA J, KVASNICA M. Comparison of MPC strategies for building control [C]. Proceedings of the 2013 International Conference on Process Control (PC), 2013: 401-406.
- [13] BAI Z, GUO D, LI S, et al. Analysis of temperature and humidity field in a new bulk tobacco curing barn based on CFD[J]. Sensors (Switzerland), 2017, 17(2), DOI: 10.3390/s17020279.
- [14] WU W, WANG B, MALKAWI A, et al. A method toward real-time CFD modeling for natural ventilation [J]. Fluids, 2018, 3(4), DOI: 10.3390/fluids3040101.
- [15] ALBATAYNEH A, ALTERMAN D, PAGE A W, et al. Warming issues associated with the long term simulation of housing using CFD analysis [J]. Journal of Green Building, 2016, 11(2): 59-74.
- [16] ALIBERTI A, BOTTACCIOLI L, MACII E, et al. A non-linear autoregressive model for indoor air-temperature predictions in smart buildings [J]. Electronics (Switzerland), 2019, 8(9): 1-17.
- [17] SONG J, XUE G, MA Y, et al. An indoor temperature prediction framework based on hierarchical attention gated recurrent unit model for energy efficient buildings [J]. IEEE Access, 2019, 7: 157268-157283.
- [18] 彭勇刚, 韦巍. 基于神经网络补偿的人工气候箱温湿度模糊控制 [J]. 仪器仪表学报, 2009, 30(7): 1373-1377.
PENG Y G, WEI W. Artificial climate chest temperature and humidity fuzzy control based on neural network compensation [J]. Chinese Journal of Scientific Instrument, 2009, 30(7): 1373-1377.
- [19] YU Y, MEGRI A C, JIANG S. A review of the development of airflow models used in building load calculation and energy simulation [J]. Building Simulation, 2019, 12(3): 347-363.
- [20] ATTOUE N, SHAHROUR I, YOUNES R. Smart building: Use of the artificial neural network approach for indoor temperature forecasting [J]. Energies, 2018, 11(2): 1-12.
- [21] AFROZ Z, SHAFIULLAH G, URMEE T, et al. Prediction of indoor temperature in an institutional building [J]. Energy Procedia, 2017, 142: 1860-1866.
- [22] XU C, CHEN H, WANG J, et al. Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method [J]. Building and Environment, 2019, 148: 128-135.
- [23] SHI X, LU W, ZHAO Y, et al. Prediction of indoor temperature and relative humidity based on cloud database by using an improved BP neural network in chongqing [J]. IEEE Access, 2018, 6: 30559-30566.

作者简介



石欣(通信作者), 分别在 2003 年和 2010 年于重庆大学获得硕士学位和博士学位, 现为重庆大学副教授, 工学博士, 博士生导师, 主要研究方向为智能控制, 无线传感器网络。

E-mail: meetshixin@gmail.com

Shi Xin (Corresponding author) received his M. Sc. degree and Ph. D. degree both from Chongqing University in 2003 and 2010, respectively. He is currently an associate professor and a Ph. D. advisor at Chongqing University. His main research interests include intelligent control and wireless sensor networks.



田文彬, 2014 年于重庆大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为建筑能源与人机融合。

E-mail: 2872828491@qq.com

Tian Wenbin received her B. Sc. degree from Chongqing University in 2014. She is currently a master student at Chongqing University. Her main research interests include building energy and human-machine fusion.