

基于 ISSA-LSTM 的热舒适短期预测模型

闫秀英, 肖桂波, 王鑫洋, 吉星星

(西安建筑科技大学 建筑设备科学与工程学院, 西安 710055)

摘要: 为解决在测试日内的短期预测过程中, 农村城镇人体热舒适中建筑惰性及人员等随机因素使人体感受变化的样本对预测结果影响大而导致预测精度低的问题, 提出基于改进麻雀搜索算法 (ISSA) 优化长短期记忆神经网络 (LSTM) 的方法建立新型户用空调热舒适短期预测模型; 首先, 对测试日气象数据进行动态性分析, 对数据进行有效性验证并构建多种热舒适预测模型; 随后选用新型用户热舒适短期预测模型 (ISSA-LSTM) 对热舒适进行预测。结果表明, 模型的最高预测均方误差 (MSE) 比麻雀搜索算法 (SSA) 和蜣螂优化算法 (DBO) 优化 LSTM 分别提高了 0.022 96 和 0.108 27, 采用 ISSA-LSTM 方法后改善了短期热舒适预测的精度问题, 并提高了分体式空调通过热舒适来控制温度的性能。

关键词: 户用空调; 热舒适; 改进麻雀搜索算法; 神经网络; 短期预测

Short-term Prediction Model for Thermal Comfort Based on ISSA-LSTM

YAN Xiuying, XIAO Guibo, WANG Xinyang, JI Xingxing

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

Abstract: During short-term prediction on test days, to solve the influence of random factors such as building inertia and personnel in human thermal comfort, resulting in the low prediction accuracy in rural and urban areas, an optimized long short-term memory neural network (LSTM) based on improvement sparrow search algorithm (ISSA) is proposed to build the novel short-term prediction model for the thermal comfort of residential air conditioners. Firstly, this paper analyzes the dynamic data of weather on test days, verifies the validity of the data, and constructs various thermal comfort prediction models; Then, the new household thermal comfort short-term prediction model (ISSA-LSTM) is selected to predict thermal comfort. The results show that compared with the sparrow search algorithm (SSA) and Dung beetle optimizer (DBO) optimized LSTM, the proposed method increases the highest prediction mean squared error (MSE) of 0.022 96 and 0.108 27, respectively. The ISSA-LSTM method is adopted to improve the accuracy of short-term thermal comfort prediction, and the performance of split air conditioners to control temperature through thermal comfort.

Keywords: residential air conditioners; thermal comfort; ISSA; neural network; short-term prediction

0 引言

随着城市生活压力大、节奏快, 越来越多的城市高收入人群向往在农村地区度过夏季炎热酷暑; 因生活水平提高, 当地人对热舒适提出了更高的要求。为提高室内人员热舒适, 不可避免的需要消耗更多的能耗。丹麦 Fanger 教授提出的 7 级分度 PMV (Predicted Mean Vote) 指标已被美国采暖制冷与空调工程师学会 ASHRAE 标准认可, 同时 Wu^[1] 等考虑 HVAC 系统中室内空气温度作为主要控制参数不能精确反映室内人员热舒适, 且受限于热舒适传感器的设定点常远离室内人员导致不能准确检测到室内人员感觉, 导致建筑运行过程中产生更多的能耗。

目前, 国内外学者主要从两个方面对准确反映室内人员热舒适进行研究, 一方面通过修正 PMV 模型内皮肤温度

参数而改进后的 PMV 模型, 计算出室内人员热舒适^[2], 还可通过修改汗液蒸发损失系数^[3] 等来改进 PMV 计算, 我国学者如张丽丽^[4] 等也在简化 PMV 的计算。而 Dyvia^[5] 等认为采用 PMV 指数模型来计算热舒适复杂, 因为影响模型参数的因素多、关系具有非线性且 PMV 系数修改耗时, 其选用人工神经网络来预测 PMV 指数。另一方面可采用数据驱动的方法, 如 Ferreira^[6-7] 等通过反向传播神经网络 (BP, back propagation neural network) 建立预测 PMV 的模型。针对影响室内人员热舒适状态因素, 王晓辉^[8] 在应用 BP 预测 PMV 时考虑了室内温度、室内湿度、室内风速和室内辐射温度, 杜晨秋^[9] 不仅考虑室内环境因素, 还考虑地理位置、性别年龄、习惯及室外环境因素作为影响因素, 周浩^[10] 研究表明人体各部位皮肤温度随环境温度的升高线性增加, 服装热阻越小会使皮肤温度对环境温度的变化越敏

收稿日期: 2023-06-05; 修回日期: 2023-07-17。

基金项目: 陕西省自然科学基金基础研究基金 (2022JM-283); 陕西省建设厅科技发展计划项目 (2020-K17)。

作者简介: 闫秀英 (1980-), 女, 博士, 副教授。

引用格式: 闫秀英, 肖桂波, 王鑫洋, 等. 基于 ISSA-LSTM 的热舒适短期预测模型[J]. 计算机测量与控制, 2024, 32(5): 230-237.

感, 且各部位皮肤温度间的差异随环境温度的升高而减小。而针对使用各类预测算法的效果, 司芙蓉^[11]为避免初始网络权阈值和预测结果陷入局部最优值且预测精度低的问题, 考虑采用遗传算法来优化 BP, 张玲^[12]则用粒子群算法改进 BP。Andrea Bellagarda^[13-14]和 Aiman^[15]等考虑热舒适数据中的时空关系分别应用长短期记忆神经网络 (LSTM, long short-term memory network) 和门控神经网络 (GRU, gate recurrent unit) 建立热舒适预测模型。针对数据平稳性、波动性及数据量问题, 蒋阳升^[16]和陈彦如^[17]通过 EnergyPlus 模拟获得大量数据预测高铁站室内热舒适, 但其对于依据某天数据来预测当天时段性的热舒适情况未知, 同时针对户用空调使用时的现实情况 (如农村地区某室内人数少) 采集大量数据不现实。对于其它领域进行预测研究的还有杨芮^[18]、王帅^[19]等使用 GRU、LSTM 预测风速、网络流量等, 但对于人体热舒适测试日一天内的短期预测效果未知。

综上, 对于在农村住宅内进行测量影响室内人员热舒适影响因素应至少包括室内温度、室内湿度、室内风速、室内辐射温度^[20]。由于室内人员的服装热阻和新陈代谢率不便测量的影响因素, 考虑人体各部位皮肤温度与环境温度存在线性关系、与服装热阻存在对数关系, 热舒适预测研究可以通过室内人员皮肤温度、室外温度进行替代。针对波动性及数据量问题, 目前热舒适预测研究中存在影响因素数据平稳性、波动性及数据量问题, 可通过将算法应用到预测短期人体热舒适验证效果。本文为解决在测试日一天内的短期预测农村城镇人体热舒适中建筑惰性以及人员等随机因素使人体感受变化的样本对预测结果影响大而导致预测精准度低的问题, 使用改进后的麻雀搜索算法优化长短期记忆神经网络 (ISSA-LSTM, improvement sparrow search algorithm optimizing long short-term memory neural network) 预测短期人体热舒适, 提出基于 ISSA-LSTM 的农村城镇室内热舒适短期预测模型。

1 实验设计

数据采集地点位于陕南农村移民搬迁住宅地区中具有代表性的 3 户家庭, 住宅主体为砖混结构, 外窗为铝合金窗框单层玻璃, 一层地面为水泥砂浆抹面二层地面为平铺瓷砖, 测量点平面图如图 1。图中的 3 户家庭在图 1 中 (a) (b) (c) 均为东西朝向的两层建筑, 测量地点位于一层, 测量点布置如图标记位置, 对于测量房间的三户居民住宅都拥有分体式空调系统, 均安装于堂屋上方的二楼房间。平时陕西南部地区在炎热、严寒时段生活的人员大多数为上学的初高中小学生、高龄老人和照顾学生与老人的青年劳动人员。

对于本次实地采集到的数据有室外温度、室内温度、室内湿度、室内干球辐射温度、室内湿球辐射温度、室内风速、受试者皮肤温度和居住者真实的热舒适感受, 通过前 7 个影响因素预测人体热舒适。热舒适感受 (Thermal Sensation Vote, TSV) 采用国际标准化组织 (ISO) 依据

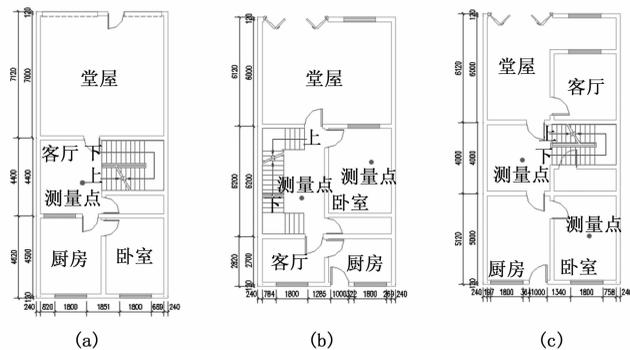


图 1 测量房间平面图

Fanger 教授的研究成果即采用七级热感觉指标: 冷、凉、微凉、中性、微暖、暖、热, 其代表值分别为 -3、-2、-1、0、1、2、3。实验采集到的一组数据作为该时段的一个样本数据, 将所采集到的全体数据组作为整体数据, 测量数据仪器型号位置布置及精度详情如表 1。

表 1 测量数据仪器型号位置布置及精度

测量参数	仪器型号	测量范围	仪器精度	布置位置
室外温度	TR72UI 型双通道温湿度记录仪	10~60 °C	±0.2 °C (25 °C)	离地 0.9 m 处
室内温度	TR72UI 型双通道温湿度记录仪	10~60 °C	±0.2 °C (25 °C)	离地高度 0.7 m 处
室内湿度	TR72UI 型双通道温湿度记录仪	5~95% RH	±2%RH (25 °C)	离地高度 0.7 m 处
室内干球辐射温度	AZ8778 型黑球温度计	1~80 °C	±0.2 °C (15~40 °C)	离地高度 0.7 m 处
室内湿球辐射温度	AZ8778 型黑球温度计	1~80 °C	±0.2 °C (15~40 °C)	离地高度 0.7 m 处
室内风速	TESTO 405 型热线风速仪	0~2 m/s	±0.1 m/s+5%测量值	离地高度 0.8 m 处
皮肤温度	AT380 液晶屏希玛红外线测温仪	0~80 °C	-0.5~+0.5 °C	贴近于受试者的手腕处

本文调查及测量数据汇总后形成原始样本数据节选如表 2。将实地采集到的 3150 组室内湿度、室内温度和调查得到的 TSV 数据绘制成三维散点图如图 2, 可以发现农村地区的室内人员较多情况下可通过移动到舒适的室内环境使自身处于 TSV 为 0 的舒适状态。对于实际采集到的数据将每天调查得到的 TSV 变化展现出测试日 TSV 的结果图如图 3。针对测量得到的室外温度及天气情况可知, 因为在日期序号为 2 和 4 的天气下雨, 导致夏季天气温度骤降使得室内人员受试者有冷的感觉, 即存在 TSV 为 -1 的情况。

2 改进麻雀搜索算法机制

在应用改进麻雀搜索算法 (ISSA, improvement sparrow search algorithm) 时, 假设麻雀种群大小为 10 只, 而

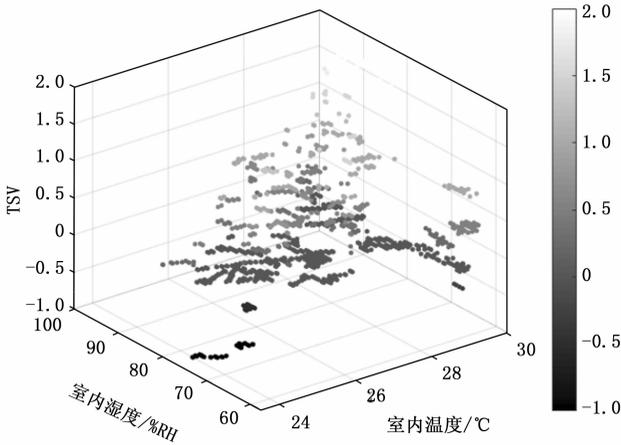


图2 测试日室内温度、室内湿度和 TSV 的散点图

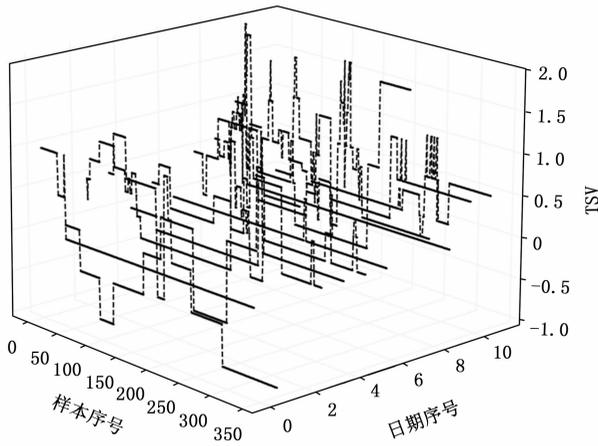


图3 测试日 TSV 的结果图

表 2 原始样本数据节选

时间	室内温度 /°C	室内相对湿度 /(%RH)	室外温度 /°C	湿球辐射温度 /°C	干球辐射温度 /°C	室内风速 / (m/s)	平均皮肤温度 /°C	平均 TSV
7/19 9:14	25.6	73.4	21.9	22.8	24.9	0	32.7	0
7/20 9:02	24.9	73.5	43.7	23.2	26.1	0	33.5	0.5
7/21 9:33	25.9	76.4	42.6	24.7	27.1	0	33.6	0.5
7/22 9:00	25.3	78.3	23.4	23.1	24.9	0	34.3	0
7/23 10:10	23.5	79.7	24.7	20.5	24.5	0	33.875	0.25
7/24 9:24	24.5	80.4	27.6	22.6	24.2	0	33.4	0
7/25 9:35	26	86.6	33.2	25.1	26.4	0	34.95	0.5
7/26 9:00	27.5	89.1	35.2	27.2	28.4	0	34.38	0.6
7/27 12:21	28.7	75.3	36.4	26.1	28.4	0	35.9	1
7/28 9:14	26.3	76.3	39.2	23.9	26.3	0.34	33.45	0
7/29 9:18	26.9	75.1	38.9	24.7	27.3	0.41	34.7	0

个体中优化变量为 3，优化变量分别为学习率和长短期记忆神经网络第一、二隐藏层神经元的个数，共迭代 20 次。麻雀的位置和能量高低将影响优化的精度，即麻雀在种群中

的适应度次序和麻雀内部优化变量的适应度值。

既有研究表明混沌映射可以保持数据的多样性，而 Tent 混沌映射可使数据更均匀的位于目标范围内，从而提高解的非线性、遍历性和随机性等多种特征，种群个体初始化采用公式 (1)。

$$X_{i,j} = \begin{cases} M_{i,j}/0.5, & 0 < M_{i,j} \leq 0.5 \\ (1 - M_{i,j})/0.5, & 0.5 < M_{i,j} \leq 1 \end{cases} \quad (1)$$

$X_{i,j}$ 表示混沌映射初始化种群后的第 i 个麻雀个体， $M_{i,j}$ 表示混沌映射初始化种群后的第 i 个麻雀个体，麻雀个体包含 j 维矩阵的随机数值。

当确定好种群麻雀中个体的数值并计算好每个个体的适应度值后，先对适应度值进行排序，排序前 70% 为探索者麻雀个体，后 30% 为加入者麻雀个体。在每次迭代的过程中对种群内每个个体进行扫描，探索者的位置更新方式为式 (2)：

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \times \exp\left(\frac{-i}{\alpha \cdot iter_{max}}\right), & \text{if } YJ < AQ \\ X_{i,j}^t + Q \cdot L, & \text{if } YJ \geq AQ \end{cases} \quad (2)$$

t 为当前迭代次数， $iter_{max}$ 表示本优化算法中的最大迭代次数； α 为 $[0, 1]$ 内随机数， YJ 属于 $[0, 1]$ ， AQ 属于 $[0.5, 1]$ 取值为 0.8 分别表示预警值和安全值，预警值和安全值是为了给当前迭代种群中较优个体保留下来，预警值 YJ 由 random 随机函数确定； Q 为服从正态分布的随机数； L 为一个 3×1 的 3 行 1 列矩阵，每个元素均为 1。 $YJ < AQ$ 表示 80% 的概率对当前种群的探索者麻雀个体进行个体寻优，更新个体值； $YJ \geq AQ$ 表示 20% 的概率对当前种群的探索者麻雀个体进行个体寻优，更新个体值。

当更新好发现者的个体后对种群内麻雀个体再比较适应度值，此时的探索者可视作已进入下一代。为使加入者大多数都可以获得食物，即为了加入的麻雀个体适应度值更优，设置条件为 $i > n/2$ ，即当前种群前五名为种群最优。加入者的位置更新方式为式 (3)：

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{i,j}^{t_{worst}} - X_{i,j}^t}{i^2}\right), & \text{if } i > \frac{n}{2} \\ X_{i,j}^{t+1} + |X_{i,j}^t - X_{i,j}^{t+1}| \cdot A^+ \cdot L, & \text{otherwise} \end{cases} \quad (3)$$

$X_{i,j}$ 为探索者最小适应度值的麻雀个体， $X_{i,j}^{t_{worst}}$ 为当前全局最差位置即适应度值最大的麻雀个体， n 表示种群规模， A 为 3×1 的 3 行 1 列矩阵，每个元素随机 -1 或 1。当 $i > n/2$ 时表示对加入者适应度值排序后的麻雀个体位置大于 $n/2$ 的麻雀个体依次进行个体位置更新，以缩小小适应度值的差距。当 $i \leq n/2$ 时表示第 i 个加入者满足所需能量要求。 A^+ 是一个 3×1 的 3 行 1 列矩阵，更新公式为式 (4)：

$$A^+ = A^T (AA^T)^{-1} \quad (4)$$

针对更新麻雀个体内的优化因素可能在更新过程会造成超过上下界的情况，则引入边界函数。由于麻雀个体的第一个优化因素为学习率介于 0 到 1 之间，而其他优化因素介于 1 到 100 之间，则需要将边界函数设置分段函数，公式为式 (5)：

$$X_{i,j}^{t+1} = \begin{cases} (ub[j] - lb[j]) \times a + lb[j], & \text{if } j = 0 \text{ 且 } [(X_{i,j}^t < lb[j]) \text{ 或 } (X_{i,j}^t > ub[j])] \\ [(ub[j] - lb[j]) \times a \times L + 1] \times lb[j], & \\ X_{i,j}^t + k \left(\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon} \right), & \text{if } j = 1, 2 \text{ 且 } [(X_{i,j}^t < lb[j]) \text{ 或 } (X_{i,j}^t > ub[j])] \end{cases} \quad (5)$$

在算法中, 假设种群内 20% 的个体会意识到危险, 这些个体的初始位置在种群中随机产生, 危险者的麻雀主要是为增强计算问题的局部寻优。公式为式 (6):

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t|, & \text{if } f_i > f_g \\ X_{i,j}^t + k \left(\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon} \right), & \text{if } f_i = f_g \end{cases} \quad (6)$$

X_{best}^t 为当前全局最优位置, β 为步长控制参数, 其值为服从均值为 0, 方差为 1 的正态分布的随机数; k 为 $[-1, 1]$ 内随机数; f_i 为当前个体适应度值; f_g, f_w 分别为当前最优、最差适应度值; ϵ 为避免分母为 0 的常数。 $f_i > f_g$ 表示当前个体劣于最优的个体, 就需要对当前个体内的优化数据进行更新, 但为避免当前个体远离最优适应度值则需要以最优个体对个体内进行数据叠加以尽量达到优于当前最优个体的效果; $f_i = f_g$ 时表明需要将当前个体内优化数据在当前个体内部数值进行叠加以远离最优个体。 k 表示正负移动方向, 因为不知道最优个体内部数据比最优适应度值大还是小, 则需要使 k 为 $[-1, 1]$ 内随机数; 同时 k 也是步长控制参数。更新好个体次序后必然有最差个体次序排在 10 以后, 则意味着挤掉了适应度较差的个体。

为增强全局搜索能力, 增加随机反向机制, 对全局最

优解进行反向搜索, 使全局搜索最大化。若反向得到的个体比全局最优解更优, 则更新全局最优个体和全局最优适应度值, 公式如 (7), 式中 r 表示 $[0, 1]$ 的随机数, lb, ub 分别表示优化参数的下限和上限。

$$X_{best}^t = lb + ub - r \times X_{best}^t \quad (7)$$

3 热舒适短期预测模型

3.1 模型预测流程

热舒适短期预测模型考虑长短期记忆神经网络, 长短期记忆神经网络预测细节如图 4, 学习率以 0.001 到 0.01 间的数值, 迭代次数以 150, 神经元个数为 10 到 100 内的参数寻优结果为主, 批量数以 4 为初始参数进行预测训练, 改进后的麻雀优化算法优化长短期记忆神经网络的热舒适短期预测模型流程图如图 4。长短期记忆神经网络和循环神经网络在继承上一批量中神经细胞的信息方面有着相同的能力, 如图 5 中批量 2 可继承批量 1 的信息。批量是一段序列, 通过每进行一次获取数据信息后即后移一次, 如图 5 中批量 1 的下一批量为批量 2。图 5 中 C 表示神经细胞内部的信息, H 表示上一时刻的神经细胞信息, X 表示神经细胞输入信息, Y 表示神经细胞输出信息。

由于批量的设置可以将优化隐藏层的权值和阈值转变为设置长短期神经网络的隐藏层神经元个数。预测过程为对数据列表化后再归一化, 再将列表化的数据进行三维处理以应对 Tensor 的数据预测规则, 同时设置好批量的值。当创建好 LSTM 模型后即可将数据分为训练数据和预测数据进行预测, 对于 LSTM 中的隐藏层输出的数量都是第二

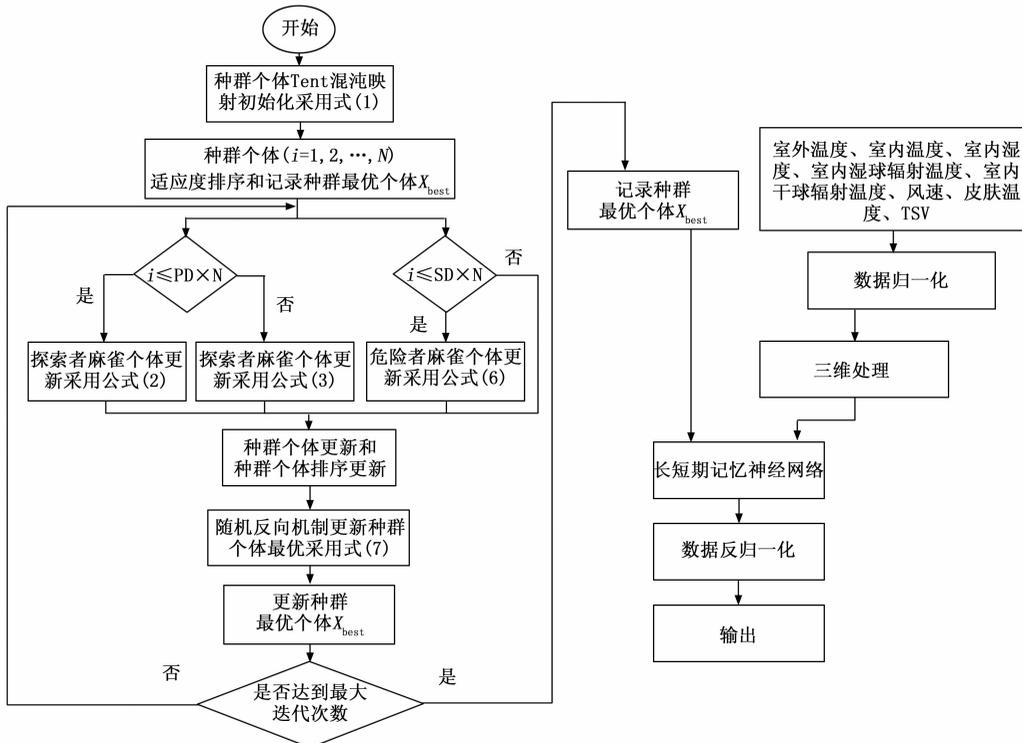


图 4 ISSA-LSTM 预测模型流程图

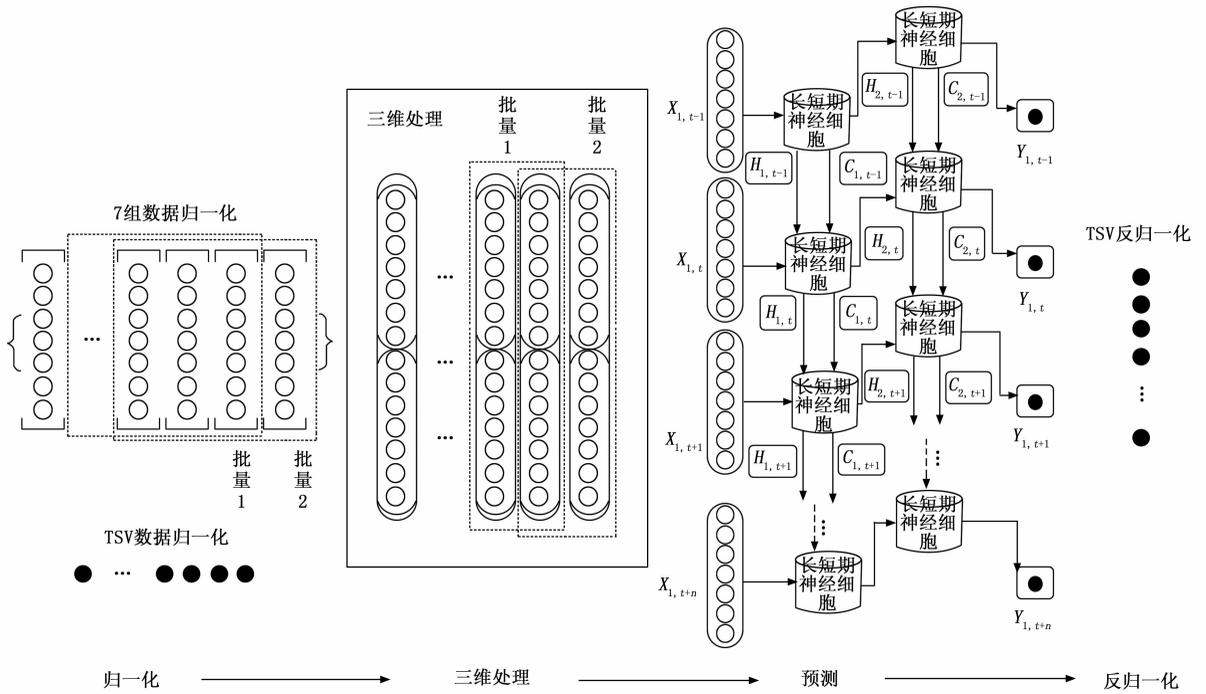


图 5 长短期记忆神经网络预测细节图

层隐藏层神经元的个数，输出结束后可进入全连接层得出序列 PMV 的数值。

3.2 评价指标

为了验证比较各预测算法的准确性，采用下面 4 种误差评价指标。

1) 均方误差 (MSE, mean squared error), 公式为式 (8):

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_{zi} - P_{yi})^2 \quad (8)$$

2) 方根误差 (RMSE, root mean squared error), 公式为式 (9):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{zi} - P_{yi})^2} \quad (9)$$

3) 平均绝对误差 (MAE, mean absolute error), 公式为式 (10):

$$MAE = \frac{1}{N} \sum_{i=1}^N |(P_{zi} - P_{yi})| \quad (10)$$

4) 平均绝对百分比误差 (MAPE, mean absolute percentage error), 公式为式 (11):

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{P_{yi} - P_{zi}}{P_{zi}} \right| \quad (11)$$

式 (8) 中的 P_{zi} 表示原始数据内的第 i 个 TSV 数据; P_{yi} 表示预测集内的第 i 个 TSV 数据; \bar{P}_{zi} 表示真实数据内的第 i 个 TSV 数据; 式 (8) ~ (11) 中 N 为预测样本内的总数量。

4 实验结果与分析

根据室内风速、室内湿球黑球辐射温度、室内相对湿

度与调查得到的 TSV 的关系，划分为不同室内空气温度下的数据得到散点图，同时得到室内空气温度分别为 24、25、26、27、28、29℃ 的拟合一次线性直线，如图 6。分析可知，在温度一定的情况下，随着室内湿球辐射温度的增加室内人员的 TSV 值增加，即室内湿球辐射温度与人体热舒适呈现正相关；随着室内相对湿度的增加室内人员的 TSV 值随之增加，即室内相对湿度与人体热舒适呈现正相关。数据验证了室内空气温度越高、室内辐射温度越高、室内相对湿度越大、室内风速越低，TSV 值越大，同时印证了数据的有效性。

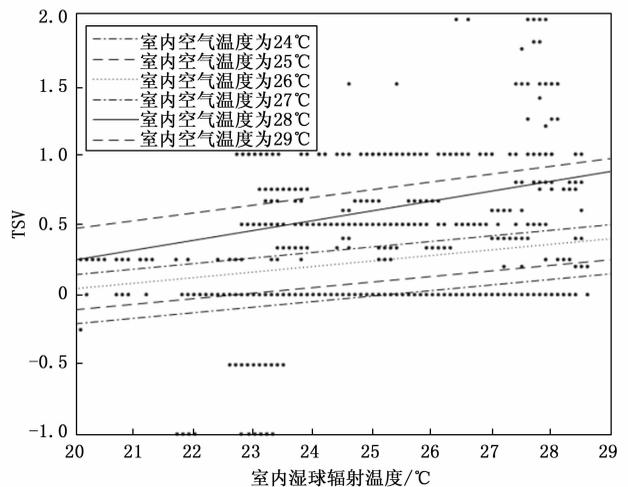


图 6 不同室温下 TSV 随室内湿球辐射温度的变化图

针对改进麻雀搜索算法的运算效果, 通过对比粒子群优化算法 (PSO, particle swarm optimization)、变色龙优化算法 (CSA, chameleon swarm algorithm)、金豺优化算法 (GJO, golden jackal optimization)、蜣螂优化算法 (DBO, dung beetle optimizer)、麻雀搜索算法 (SSA, sparrow search algorithm) 和改进麻雀搜索算法 (ISSA) 计算基准多维函数名为 Quartic Function, 设置个体维度均为 30, 迭代次数均为 500 次, 函数自变量区间为 $[-1.28, 1.28]$, 计算最优结果分别 17.240 6、0.195 78、0.001 36、 $4.702 18 \times 10^{-4}$ 、 $1.496 89 \times 10^{-4}$ 和 0。各优化算法计算 Quartic Function 函数计算最优值结果图如图 7, 可见改进麻雀搜索算法对于计算多峰问题有最好的寻优能力。优化算法相关参数设置表如表 3, 下面应用优化算法的参数同表 3。

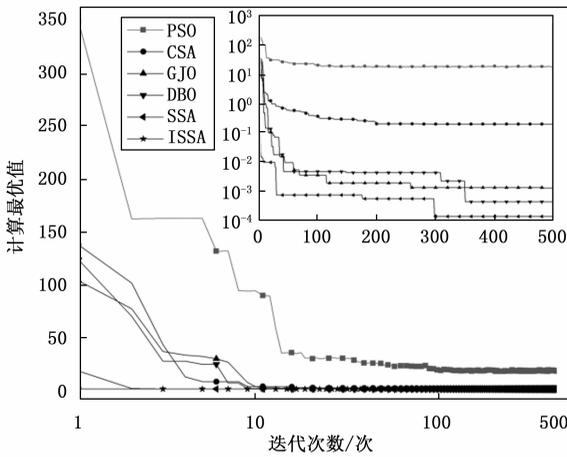


图 7 各优化算法计算 Quartic Function 函数计算最优值结果图

表 3 各优化算法参数设置表

优化算法名称	参数设置
粒子群算法 (PSO)	惯性因子为 0.7; 学习因子为 2;
变色龙算法 (CSA)	控制搜索能力的参数 p_1 为 0.1; p_2 为 0.9; 步长的影响程度 c_1 为 2; c_2 为 1.8; 惯性因子取 0.5。
金豺优化算法 (GJO)	猎物能量的下降过程中 c_1 为 1.5, 莱维飞行函数中 β 为 1.5
蜣螂优化算法 (DBO)	角色比例分别为 6:6:7:11, λ 为 0.1, b 为 0.3, 偏转系数 k 为 0.1
麻雀搜索算法 (SSA)	探索比例 PD 为 0.7, 危险比例 SD 为 0.2, 安全值 AQ 为 0.8
改进麻雀搜索算法 (ISSA)	参数同上 SSA

对于测得的数据, 仅考虑测试日一天内的室外温度、室内温度、室内湿度、室内湿球辐射温度、室内干球辐射温度、室内风速、室内人员皮肤温度, 使用模型分别采用

支持向量机 (SVM, support vector machine)、BP、CSA 分别优化 SVM 和 BP、SSA 分别优化 SVM 和 BP。以测试日序号为 1 的有序热舒适数据为例, 通过不同优化算法的 BP 与 SVM 预测模型预测室内人员 TSV 得到的最优结果 RMSE 为 0.004 061 9, 最优结果的 MAE 为 0.004 040 8, 最优预测为 SSA-BP 的模型。针对有序的训练集应用不同优化算法的 BP 与 SVM 预测模型预测室内人员有序热舒适数据得到的最优 MSE 的结果为 $9.95E-05$, 最优预测为 CSA-SVM 的模型。对于 BP 和 SVM 而言, 预测集的预测范围分别在 $[-0.001, 0.01]$ 和 $[0.1, 0.28]$ 区间内; 对于增添优化算法的 BP 和 SVM, 预测集的预测范围分别在 $[-0.05, 0.025]$ 和 $[-0.01, 0.245]$ 区间内, 可见关于 BP 和 SVM 的预测模型不适用于短期热舒适预测模型。且在测试日内的短期预测过程中, 存有农村城镇人体热舒适中建筑惰性及人员等随机因素使人体感受变化的样本对预测结果影响大而导致预测精准度低的问题。

应用 DBO、SSA 和 ISSA 优化 LSTM 预测测试日序号为 2 的热舒适数据, 以种群大小为 10, 迭代 10 次, 设置各参数范围分别为 $[0.001, 0.01]$ 、 $[1, 100]$ 和 $[1, 100]$ 为例, DBO、SSA 和 ISSA 优化 LSTM 各参数结果图如图 8。通过前 3 次的迭代训练 ISSA 优化的学习率已趋于不变, 而 DBO 和 SSA 还处于局部寻优和全局寻优的波动搜索中, DBO 和 SSA 分别经过前 6 次和前 4 次迭代训练 LSTM 中各优化参数后最优解才趋于不变。通过 DBO、SSA 和 ISSA 优化 LSTM 预测得到的 MSE 分别为 0.009 66、0.003 62、0.001 53, 可见 ISSA 改进了局部搜索能力和全局搜索能力, 提升了 SSA 寻找到问题最优值的速度, 也提高了问题最优值精度。考虑预测得到的波动情况, 应用 DBO、SSA 和 ISSA 优化 LSTM 预测得到的 MAPE 分别为 0.066 05、0.055 36、0.036 45, 可见 ISSA 优化 LSTM 预测得到的 TSV 波动范围更小。

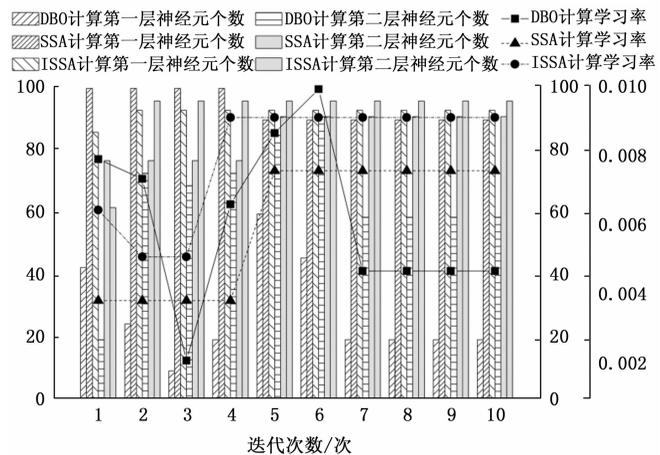


图 8 DBO、SSA 和 ISSA 优化 LSTM 各参数结果图

应用 DBO、SSA 和 ISSA 优化 LSTM 预测测试日序号

为 1、2 和 3 的热舒适数据，从整体而言，ISSA-LSTM 预测的更精准。对于预测序号为 1 的热舒适原始数据，由于原始数据均为 TSV 为 0 的数据，考虑分母不能为 0 则针对预测集的 MAPE 的结果为空。尽管预测测试日序号为 1 的 SSA-LSTM 和 ISSA-LSTM 对于 MSE、RMSE 和 MAE 结果相差不大，但是预测测试日序号为 2 和 3 的热舒适数据有大于 2 倍的 MSE 缩小。对于测试日序号为 3 的热舒适数据，部分预测集热舒适数据在训练集中不存在，但是 ISSA-LSTM 对预测集的数据预测 MSE、RMSE、MAE 和 MAPE 分别为 0.000 17、0.012 91、0.009 28、0.010 37。预测的效果图如图 9，其中测试日间用 50 组空序列隔开图中用虚线连接。

应用 DBO、SSA 与 ISSA 分别优化 LSTM 预测测试日内热舒适数据结果误差表如表 4，由表 4 可知对于序号为 5 和 7 的测试日，应用 DBO、SSA 与 ISSA 优化 LSTM 预测人体热舒适有明显的对比预测效果。针对序号为 5 的测试日，ISSA-LSTM 预测的最优结果 MSE 比 SSA-LSTM、DBO-LSTM 的 MSE 分别增加了 0.022 96 和 0.058 03，而预测的最优结果 MAE 分别增加了 0.087 82 和 0.139 32。针对序号为 11 的测试日，ISSA-LSTM 预测的最优结果 MSE 比 SSA-LSTM、DBO-LSTM 的 MSE 分别提高了 0.009 91 和 0.108 27，而预测的最优结果 MAE 分别增加了 0.046 02 和 0.246 14。

对于测试日序号从 1 到 11 的热舒适数据训练集中，可

表 4 应用 DBO、SSA 与 ISSA 分别优化 LSTM 预测测试日内热舒适数据结果误差表

序号	模型	训练集				预测集			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
1	DBO	0.003 03	0.055 03	0.037 32	0.010 66	0.020 56	0.143 40	0.127 31	无
	SSA	0.000 26	0.015 98	0.012 66	0.005 46	0.000 16	0.012 84	0.011 47	无
	ISSA	0.000 13	0.011 49	0.009 12	0.002 24	0.000 14	0.011 91	0.010 71	无
2	DBO	0.004 90	0.070 02	0.045 23	0.055 42	0.009 66	0.098 30	0.065 08	0.066 05
	SSA	0.000 48	0.021 96	0.014 06	0.016 43	0.003 62	0.060 17	0.054 98	0.055 36
	ISSA	0.001 33	0.036 45	0.023 42	0.028 32	0.001 53	0.039 09	0.035 90	0.036 45
3	DBO	0.001 05	0.032 39	0.025 18	0.016 88	0.019 03	0.137 93	0.096 43	0.080 92
	SSA	0.000 26	0.016 07	0.013 24	0.009 57	0.001 50	0.038 78	0.030 35	0.023 13
	ISSA	0.000 07	0.008 60	0.005 99	0.005 57	0.000 17	0.012 91	0.009 28	0.010 37
4	DBO	0.000 39	0.019 81	0.010 08	0.007 44	0.003 88	0.062 31	0.047 89	0.008 93
	SSA	0.000 07	0.008 42	0.006 20	0.004 71	0.000 25	0.015 78	0.009 62	0.001 52
	ISSA	0.000 07	0.008 30	0.005 94	0.004 96	0.000 20	0.014 29	0.010 06	0.002 26
5	DBO	0.009 65	0.098 22	0.054 65	0.029 52	0.067 17	0.259 16	0.219 82	0.091 57
	SSA	0.007 08	0.084 15	0.052 48	0.024 19	0.032 10	0.179 17	0.168 32	0.040 01
	ISSA	0.001 70	0.041 19	0.028 33	0.011 72	0.009 14	0.095 62	0.080 50	0.007 13
6	DBO	0.000 97	0.031 21	0.020 79	0.014 93	0.001 36	0.036 86	0.027 80	0.038 36
	SSA	0.000 12	0.011 01	0.008 15	0.006 19	0.001 06	0.032 49	0.029 58	0.028 50
	ISSA	0.000 28	0.016 86	0.014 11	0.010 89	0.000 06	0.008 06	0.006 79	0.003 62
7	DBO	0.004 49	0.066 99	0.055 62	0.003 81	0.046 33	0.215 23	0.181 05	0.150 45
	SSA	0.000 03	0.005 72	0.004 66	0.000 40	0.001 11	0.033 35	0.027 94	0.032 02
	ISSA	0.000 22	0.014 88	0.011 61	0.001 31	0.000 25	0.015 91	0.008 66	0.016 59
8	DBO	0.000 10	0.010 05	0.008 27	0.006 98	0.019 99	0.141 38	0.110 90	0.056 41
	SSA	0.000 19	0.013 95	0.010 74	0.009 43	0.003 12	0.055 86	0.043 90	0.032 90
	ISSA	0.000 21	0.014 36	0.010 77	0.010 80	0.000 77	0.027 73	0.022 69	0.014 66
9	DBO	0.001 33	0.036 47	0.020 70	0.017 09	0.000 70	0.026 41	0.022 74	0.038 19
	SSA	0.001 34	0.036 58	0.022 46	0.021 14	0.000 95	0.030 89	0.025 51	0.058 23
	ISSA	0.000 61	0.024 78	0.014 97	0.012 00	0.000 38	0.019 58	0.016 28	0.022 29
10	DBO	0.001 08	0.032 89	0.025 09	0.020 60	0.006 71	0.081 91	0.079 25	0.157 95
	SSA	0.000 06	0.007 65	0.005 77	0.004 56	0.000 80	0.028 33	0.025 80	0.051 11
	ISSA	0.000 26	0.016 27	0.012 70	0.011 48	0.000 07	0.008 07	0.005 90	0.011 51
11	DBO	0.012 09	0.109 97	0.077 29	0.064 01	0.114 45	0.338 31	0.309 26	0.415 99
	SSA	0.000 22	0.014 77	0.011 04	0.011 70	0.016 09	0.126 85	0.109 14	0.161 44
	ISSA	0.000 17	0.012 86	0.009 35	0.008 62	0.006 18	0.078 61	0.063 12	0.106 56

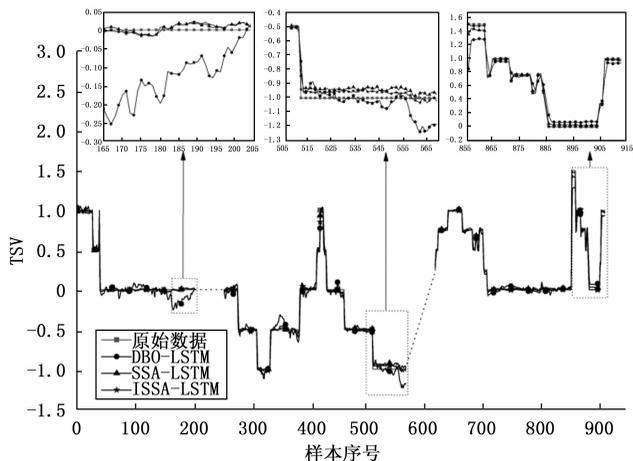


图9 DBO、SSA和ISSA优化LSTM预测测试日序号为1、2和3的热舒适数据效果图

以更好的训练ISSA-LSTM模型。其中ISSA-LSTM模型在训练集中计算得到的最小MSE可达到0.00007,但是SSA-LSTM模型在训练集中最小MSE值为0.00006时,预测得到的数据中MSE仍远远大于ISSA-LSTM模型。其中在测试日序号为4的热舒适数据能得到较强训练, RMSE、MAE和MAPE分别达到0.00830、0.00594、0.00496。

5 结束语

本文提出基于ISSA-LSTM的农村城镇室内热舒适短期预测模型进行预测短期人体热舒适研究。研究结果表明:

1) 对于测试日一天内的有序样本采用BP和SVM模型预测,应用优化算法改进神经网络的方法可提高预测精度。通过对比SVM和BP预测效果,BP模型及增添了优化算法的BP模型的预测效果更好但仍存在波动性大的影响。

2) 在测试日内对农村城镇室内人员人体热舒适进行短期预测,选用ISSA-LSTM模型预测热舒适,预测的结果比SVM、BP、DBO-LSTM和SSA-LSTM预测效果好。在短期预测模型预测热舒适的结果中最小的MSE可达到0.00006,模型的预测精度最高比SSA-LSTM和DBO-LSTM分别提高了0.02296和0.10827,改善了短期预测的精度问题,为分体式空调通过热舒适指标调节参与需求响应的研究提供基础。

参考文献:

- [1] WU J, LI X D, LIN Y, et al. A PMV-based HVAC control strategy for office rooms subjected to solar radiation [J]. *Building and Environment*, 2020, 177: 1-10.
- [2] XU G, AN Q Q. Prediction of human thermal sensation based on improved PMV model [J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 680: 1-5.
- [3] OMIDVAR A, KIM J. Modification of sweat evaporative heat loss in the PMV/PPD model to improve thermal comfort predic-

tion in warm climates [J]. *Building and Environment*, 2020, 176: 1-10.

- [4] 张丽丽, 王晓龙, 张林华, 等. 北方办公建筑地板供冷系统PMV-PPD简化计算 [J]. *山东建筑大学学报*, 2022, 37 (4): 45-50.
- [5] A DYVIA H, ARIF C. Analysis of thermal comfort with predicted mean vote (PMV) index using artificial neural network [J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 622: 1-12.
- [6] FERREIRA P M, RUANO A E, SILVA S, et al. Neural networks based predictive control for thermal comfort and energy savings in public buildings [J]. *Energy and Buildings*, 2012, 55: 238-251.
- [7] CASTILLA M, ALVAREZ J D, ORTEGA M G, et al. Neural network and polynomial approximated thermal comfort models for HVAC systems [J]. *Building and Environment*, 2013, 59: 107-115.
- [8] 王晓辉, 邱映, 杨亚龙. 基于热舒适度和焓值的室内环境联控策略 [J]. *科学技术与工程*, 2022, 22 (15): 6270-6277.
- [9] 杜晨秋, 李百战, 刘红, 等. 基于决策树模型的居住建筑人员热舒适预测 [J]. *暖通空调*, 2018, 48 (8): 42-48.
- [10] 周浩. 人体皮肤温度影响因素实验研究 [D]. 西安: 西安建筑科技大学, 2013.
- [11] 司芙蓉. 基于PMV指标的大空间环境优化控制研究 [D]. 西安: 西安建筑科技大学, 2019: 18-28.
- [12] 张玲, 王玲, 吴桐. 基于改进的粒子群算法优化反向传播神经网络的热舒适度预测模型 [J]. *计算机应用*, 2014, 34 (3): 775-779.
- [13] ANDREA B, SILVIA C, ALESSANDRO A, et al. Effectiveness of neural networks and transfer learning for indoor air-temperature forecasting [J]. *Automation in Construction*, 2022, 140: 1-25.
- [14] NIVETHITHA S, ANIRUDH S, ANUPAMA K, et al. A hybrid deep transfer learning strategy for thermal comfort prediction in buildings [J]. *Building and Environment*, 2021, 204: 1-13.
- [15] QURESHI A M, RACHID A. Heat Stress Modeling Using Neural Networks Technique [J]. *IFAC-PapersOnLine*, 2022, 55: 13-18.
- [16] 蒋阳升, 王胜男, 涂家祺, 等. 面向高铁站的热舒适度和能耗综合预测 [J]. *计算机应用*, 2021, 41 (1): 249-257.
- [17] 陈彦如, 张涂静娃, 杜千, 等. 基于深度森林的高铁站室内热舒适度等级预测 [J]. *计算机应用*, 2021, 41 (1): 258-264.
- [18] 杨芮, 徐虹, 文武. 基于EEMD-GRU网络模型的短期风速预测 [J]. *计算机系统应用*, 2022, 31 (6): 231-237.
- [19] 王帅, 董育宁, 李涛. 基于LSTM和特征生成的网络流量分类 [J]. *应用科学学报*, 2022, 40 (5): 758-769.
- [20] 庞春美, 翟永超, 杨柳, 等. 北海地区农村居民人体热舒适研究 [J]. *暖通空调*, 2018, 48 (4): 83-88.