

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2022.0872

# 基于 IPSO-AM-LSTM 的飞机地面空调能耗预测

刘涵, 林家泉\*

(中国民航大学 电子信息与自动化学院, 天津 300300)

**摘要:** 作为一个复杂的热力系统, 飞机地面空调能耗受到多种因素的影响, 包括各种天气数据和特征。为提升飞机客舱使用地面空调制冷时地面空调能耗预测精度, 构造了一种基于长短时记忆网络 (LSTM) 的地面空调能耗预测模型。该模型融合长短时记忆网络和注意力机制构建预测部分, 用于提取和利用数据中的时序信息, 并以预测精度作为算法的适应度函数, 提出一种基于改进粒子群优化 (IPSO) 算法的超参数优化方法, 与标准粒子群优化 (PSO) 算法相比, 该优化算法将迭代次数与适应度相结合, 构建了惯性权重的动态调节函数, 对其进行动态调节, 并引入粒子到全局最优位置的距离参数, 提出一种粒子交叉策略, 提高粒子群的多样性。所提方法在实际数据集上的仿真预测结果的均方误差为 4.394, 平均绝对百分比误差为 0.774%, 决定系数为 0.968。与其他预测方法进行对比, 结果表明: 所提方法有更高的准确度。

**关键词:** 飞机客舱; 地面空调; 能耗预测; 粒子群优化; 长短时记忆神经网络

**中图分类号:** V351.3

**文献标志码:** A

**文章编号:** 1001-5965(2024)11-3595-08

随着中国经济的发展和人口增长的加快, 社会对能源的需求日益增加, 对环境的保护意识也逐渐增强。为减少航空煤油燃烧对环境的污染, 提高配电效率, 减少能源浪费, 中国民用机场主要采用地面专用设备代替飞机辅助动力系统 (auxiliary power unit, APU), 从而为飞机地面作业提供动力和空调供应。因此设计准确的地面空调能耗预测模型对机场绿色减排的推动起着至关重要的作用<sup>[1]</sup>。

然而, 地面空调能耗数据的非线性、非平稳和多季节性<sup>[2]</sup>, 以及它对天气条件、客舱内环境等因素的依赖性, 使得准确预测能耗成为一项具有挑战性的任务。近年来, 传感器技术和通信技术的快速发展为数据驱动方法提供了大量的数据支持<sup>[3]</sup>, 并且由于数据驱动方法具有易用、高精度等特性, 所以被广泛地应用在能耗预测中。王修岩等<sup>[4]</sup>提出使用小波神经网络来构建飞机客舱能耗预测模型, 并使用混合粒子群算法对模型参数进行优化; 林家

泉等<sup>[5]</sup>提出使用具有短期记忆能力的 Elman 神经网络建立飞机客舱的能耗预测模型, 增强模型处理动态数据的能力; Guneet 等<sup>[6]</sup>开发一种 Elman-循环神经网络 (recurrent neural network, RNN) 模型, 使其能适应各种物联网驱动的建筑环境并用于预测电能消耗。以上研究均取得了较好的预测结果, 但忽视了能源消耗与时间之间的关系, 并且“梯度消失和梯度爆炸问题”是 RNN 一直存在的问题, 因此它很难学习长期的依赖关系<sup>[7]</sup>。为解决这一问题, Hochreiter<sup>[8]</sup>提出了一种基于门单元的 RNN 结构, 即长短时记忆 (long short term memory, LSTM) 网络结构。由于 LSTM 网络能保存时间特性, 所以已被广泛地应用于图像处理、语音识别和医疗诊断中<sup>[9-11]</sup>。然而 LSTM 网络的超参数配置对模型的预测精度具有重大的影响<sup>[12]</sup>, 因此选取一种智能算法来提高 LSTM 的性能一直是一个研究热点<sup>[13]</sup>。Ma 等<sup>[14]</sup>使用正余弦算法 (sine cosine algorithm, SCA)

收稿日期: 2022-10-30; 录用日期: 2022-12-18; 网络出版时间: 2023-01-04 10:30

网络出版地址: link.cnki.net/urlid/11.2625.V.20230103.1817.005

\*通信作者. E-mail: jqin@cauc.edu.cn

**引用格式:** 刘涵, 林家泉. 基于 IPSO-AM-LSTM 的飞机地面空调能耗预测 [J]. 北京航空航天大学学报, 2024, 50 (11): 3595-3602.

LIU H, LIN J Q. Energy consumption prediction of aircraft ground air conditioning based on IPSO-AM-LSTM[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (11): 3595-3602 (in Chinese).

优化 LSTM 网络,对基于表面肌电信号的上肢运动联合角度进行估计,仿真结果表明,该模型在估计精度上具有显著的提升,但正弦算法的精度和收敛性容易受到内部参数的影响,存在稳定性不佳的问题;周璇等<sup>[15]</sup>采用蚁狮优化算法优化 LSTM 网络,仿真结果证明了该算法在飞机地面空调能耗预测问题上有效,但预测精度仍有提升空间;Ren 等<sup>[16]</sup>采用粒子群优化 (particle swarm optimization, PSO) 算法对 LSTM 网络进行优化,对锂离子电池荷电状态进行预测,结果表明,该模型在 0.5% 的误差范围内能收敛到真实状态,但这仅考虑了搜索空间简单、极值点较少的情况,面对复杂的搜索问题,仍需要对算法开展进一步研究。

结合上述分析,本文提出了一种基于粒子群优化长短时记忆网络 (IPSO-AM-LSTM) 的飞机地面空调能耗预测模型,用于飞机地面空调能耗预测。该能耗预测模型由 2 部分组成:预测部分和超参数优化部分。预测部分融合了 LSTM 网络和注意力机制 (attention mechanism, AM),用于捕捉能耗数据与时间的相互关系。超参数优化部分则采用 IPSO 算法寻找最优的超参数配置,提高模型的预测精度。将 IPSO-AM-LSTM 模型用于对 Boeing737-800 飞机地面空调能耗预测,并与反向传播神经网络 (Back propagation nerusl work, BP)、LSTM、AM-LSTM、SCA-AM-LSTM、PSO-AM-LSTM 等多种模型进行比较,结果表明,该模型在均方误差、平均绝对值误差及决定系数上都具有显著的优势。

## 1 相关理论

### 1.1 LSTM 神经网络

RNN 是一种用于处理时间序列的神经网络,与传统卷积神经网络 (convolutional neural network, CNN) 相比,其采用循环结构来替代前馈神经网络的隐含层。在信息传递过程中,每个周期都会留下部分信息在当前神经元中,将其作为下一个神经元的输入。然而,当输入时间序列过长时,RNN 就会出现“梯度消失现象”<sup>[6]</sup>。LSTM 神经网络在 RNN 的基础上增加了存储单元和门单元来解决“梯度消失问题”,其内部结构如图 1 所示;计算过程如式 (1)~式 (7) 所示。

$$i_t = \sigma(W_i^x x_t + W_i^h h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_f^x x_t + W_f^h h_{t-1} + b_f) \quad (2)$$

$$o_t = \sigma(W_o^x x_t + W_o^h h_{t-1} + b_o) \quad (3)$$

$$g_t = \tanh(W_c^x x_t + W_c^h h_{t-1} + b_c) \quad (4)$$

$$c_t = f_t c_{t-1} + i_t g_t \quad (5)$$

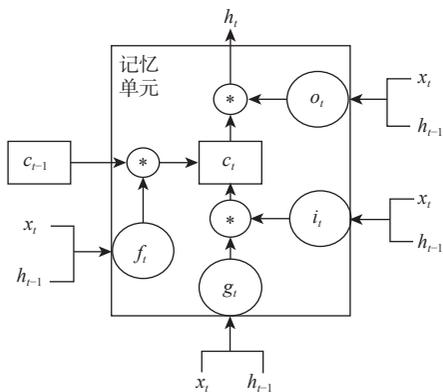


图 1 LSTM 神经网络内部结构

Fig. 1 Internal structure of LSTM

$$h_t = o_t \tanh(c_t) \quad (6)$$

$$y_t = (W_y^h h_t + b_y) \quad (7)$$

式中:  $W_i^x$ 、 $W_f^x$ 、 $W_o^x$ 和 $W_c^x$ 为输入权重矩阵;  $W_i^h$ 、 $W_f^h$ 、 $W_o^h$ 和 $W_c^h$ 为递归权重矩阵;  $W_y^h$ 为隐藏输出权重矩阵;  $b_n$ 为偏置 ( $n \in \{i, f, o, c, y\}$ );  $x_t$ 为当前时刻输入;  $y_t$ 为当前时刻输出;  $c_t$ 为长期记忆;  $h_t$ 为短期记忆;  $\sigma(\cdot)$ 为 sigmoid 激活函数,  $\tanh(\cdot)$ 为 tanh 激活函数。

LSTM 的权重和偏置的初始值是随机生成的,其通常采用标准梯度下降 (standard gradient descent, SGD) 法来反向更新权重和偏置。但是 SGD 的性能依赖于超参数,如学习率和隐藏单元数等。因此需要确定超参数的最优值,以提高 LSTM 模型的预测精度。

### 1.2 PSO 算法

PSO 算法是由 Eberhart 和 Kennedy 提出的一种全局搜索算法,其模拟了自然界中的鸟群觅食活动<sup>[7]</sup>。鸟群中的每个个体被看作作粒子,粒子是搜索空间中的有效解,对其进行迭代搜索可以得到最优解。假设  $N$  代表粒子群的粒子数目,  $t$  代表当前迭代次数,则 PSO 算法运算步骤如下。

**步骤 1** 初始化粒子的位置和速度。

**步骤 2** 计算粒子的适应度,将搜寻到的个体极值位置记为  $P_{best,i}$ ,将个体极值与种群中其他极值进行比较,选出最优的个体极值位置作为全局最优位置  $G_{best}$ 。

**步骤 3** 粒子  $i$  的第  $j$  维的速度和位置分别按照式 (14) 和式 (15) 进行更新。

**步骤 4** 如果未达到设定迭代数目,将返回步骤 2; 否则,输出  $G_{best}$ 。

计算过程如式 (8)~式 (15) 所示。

$$V_i = \{V_{i1}, V_{i2}, \dots, V_{id}\} \quad (8)$$

$$x_i = \{x_{i1}, x_{i2}, \dots, x_{id}\} \quad (9)$$

$$P_{best,i} = \{P_{best,i1}, P_{best,i2}, \dots, P_{best,id}\} \quad (10)$$

$$F(x_1, x_2, \dots, x_N) = \{f_1, f_2, \dots, f_N\} \quad (11)$$

$$P_{\text{best},i} = \begin{cases} P_{\text{best},i}(t) & f_g(x(t+1)) \geq f_g(P_{\text{best},i}(t)) \\ x(t+1) & f_g(x(t+1)) < f_g(P_{\text{best},i}(t)) \end{cases} \quad (12)$$

$$G_{\text{best}}(t) = \min \{f_g(P_{\text{best},1}(t)), f_g(P_{\text{best},2}(t)), \dots, f_g(P_{\text{best},N}(t))\} \quad (13)$$

$$V_{ij}(t+1) = wV_{ij}(t) + c_1r_1 [P_{\text{best},ij}(t) - x_{ij}(t)] + c_2r_2 [g_{\text{best},j}(t) - x_{ij}(t)] \quad (14)$$

$$x_{ij}(t+1) = x_{ij}(t) + V_{ij}(t+1) \quad (15)$$

式中:  $w$  为惯性权重;  $i$  为粒子群的粒子数目,  $i=1, 2, \dots, N$ ;  $j$  为搜索空间的维度,  $j=1, 2, \dots, d$ ;  $V_{ij}(t)$  为迭代  $t$  次后, 粒子的速度;  $x_{ij}(t)$  为迭代  $t$  次后, 粒子的位置;  $c_1$  和  $c_2$  为学习因子;  $P_{\text{best},ij}$  为第  $i$  个粒子的个体极值位置的第  $j$  维值;  $g_{\text{best},j}$  为全局最优位置的  $j$  维值;  $r_1$  和  $r_2$  为  $[0, 1]$  的随机数。

## 2 IPSO-AM-LSTM 模型

飞机地面空调能耗主要受到 3 方面影响: ①飞机停靠地的外部环境, 包括环境温度、环境湿度和光照强度等; ②飞机客舱内部的初始环境, 包括初始温度、初始湿度等; ③地面空调工作后飞机舱内要达到的目标环境, 包括舱内的目标温度、目标湿度等。其中外部环境对飞机地面空调能耗影响较大, 具有较强的时间规律, 因此将时序特征引入模型的研究中, 提出 IPSO-AM-LSTM 模型。

### 2.1 预测部分

预测部分主要由 LSTM 神经网络和注意力机制构成, 并增加 Dropout 层以避免模型训练时因训练样本较少而出现拟合现象。构造的预测部分包括输入层、LSTM 层、Dropout 层、Dense 层、AM 层和输出层。预测部分结构如图 2 所示。

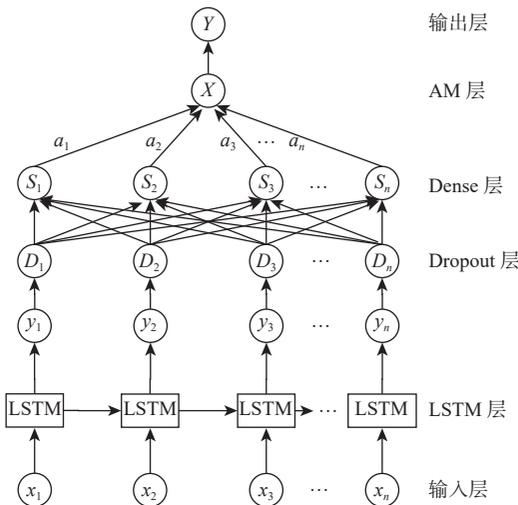


图 2 预测部分结构

Fig. 2 Structure diagram of prediction section

各层的作用如下:

1) 输入层。将地面空调工作前后的客舱数据(初始温度、初始湿度、目标温度、目标湿度)作为模型的输入, 其表达式为

$$x_n = \{P(t), Q(t), H(t), M(t)\} \quad (16)$$

式中:  $P(t)$  为地面空调工作前的客舱温度;  $Q(t)$  为地面空调工作后的客舱温度;  $H(t)$  为地面空调工作前的客舱湿度;  $M(t)$  为地面空调工作后的客舱湿度。

2) LSTM 层。利用 LSTM 神经网络捕捉输入序列  $x_n$  中的时间信息, 输出含有时序特征的序列  $y_n$ 。

3) Dropout 层。以指定的丢弃概率对 LSTM 神经网络输出序列  $y_n$  进行抛弃, 增加各神经元特征间的正交性, 提高模型的鲁棒性。

4) Dense 层。对 Dropout 层的输出进行非线性变换, 加强时间序列与预测结果之间的联系。

5) AM 层。产生注意力感知的特征, 强调处理对象的重要信息, 同时抑制一些无关细节信息。

6) 输出层。使用全连接层对上一层的结果进行降维, 得到模型需要的输出维度。

### 2.2 超参数优化部分

合理配置超参数对模型的性能至关重要。考虑到所提出的模型结构较为复杂, 提出一种 IPSO 算法对模型超参数进行优化, 以提高模型的预测精度。相比于传统 PSO 算法, IPSO 算法对粒子更新机制和惯性权重进行了改进。主要有以下改进: ①为了增加种群的多样性, 提出一种基于欧氏距离的交叉策略, 对满足条件的粒子进行交叉; ②为了改善 PSO 算法的收敛速度和精度, 构建一种新的惯性权重函数, 使算法在迭代前期有较快的搜索速度, 提高全局搜索能力, 后期减小粒子的速度, 缓慢更新粒子位置, 提高寻优能力和稳定性; ③为避免粒子群陷入局部最优, 引入一种跳出局部最优的策略, 对陷入停滞的粒子进行初始化以增强粒子活力。

#### 2.2.1 基于欧氏距离的交叉策略

##### 1) 交叉条件

模拟生物间的进化现象, 使迭代过程中当前全局最优个体  $G_{\text{best}}$  得到保留; 其余粒子对应的个体都存在交叉的可能。粒子的交叉条件如式 (17)~式 (19) 所示<sup>[5]</sup>。

$$K = \frac{R(t)}{R_{\text{max}}(t)} \quad (17)$$

$$\frac{R(t)}{R_{\text{max}}(t)} > C \quad (18)$$

$$R(t) = \sqrt{(x_{i1}(t) - g_{\text{best},1}(t))^2 + \dots + (x_{ij}(t) - g_{\text{best},j}(t))^2} \quad (19)$$

式中:  $R(t)$  为当前粒子与全局最优位置的距离;  $R_{\max}(t)$  为第  $t$  次迭代中距离全局最优粒子的最远距离;  $C$  为常数, 取值范围为  $[0,1]$ , 本文设定  $C=0.8$ ;  $x_{ij}(t)$  为第  $t$  次迭代中第  $i$  个粒子的  $j$  维值;  $g_{\text{best}_j}$  为第  $t$  次迭代中全局最优粒子的  $j$  维值。

## 2) 交叉策略

为了提高种群的多样性和加快收敛速度, 通过交叉策略更新满足交叉条件的粒子。本文采用的单点交叉, 从当前代中选取  $0 < K < 0.5$  的粒子作为双亲样本之一与满足交叉条件的粒子进行染色体互换, 以创建代表后代的粒子, 交叉策略如图 3 所示。

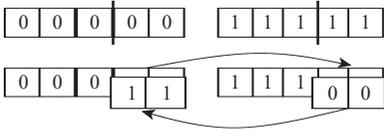


图 3 交叉策略

Fig. 3 Crossover strategy

## 2.2.2 自适应惯性权重

由式 (14) 和式 (15) 可知, PSO 算法通过变化粒子的位置实现寻优, 而粒子位置变化与惯性权重有关, 因此惯性权重的取值对算法性能和效率至关重要。文献 [18] 将基于适应度的同构因子引入式 (15) 中来控制粒子的位置变化; 文献 [19] 引入迭代次数, 对惯性权重进行动态调节。上述方案均取得了一定的效果, 但仅使用适应度或迭代次数的单一调节, 很难使粒子群算法达到最佳效果, 需要进行适应度和迭代次数的共同调节。因此, 本文构建了一种具有连续非线性的自适应惯性权重。改进后的表达式如式 (20) 所示。本文中  $w$  的取值范围为  $[0.4, 0.9]^{[5]}$ 。

$$w = \left( w_{\min} + \frac{(w_{\max} - w_{\min})(f(x_i^t) - w_{\text{worst}})}{(f(x_{\text{gbest}}) - w_{\text{worst}})} (1 - (t/t_{\max})^3) \right) \quad (20)$$

式中:  $w_{\min}$  为惯性权重最小值;  $w_{\max}$  为惯性权重最大值;  $f(x_{\text{gbest}})$  和  $w_{\text{worst}}$  分别为当前迭代过程中全局最优的粒子适应度值和全局最差的粒子适应度值;  $f(x_i^t)$  为第  $t$  次迭代时第  $i$  个粒子适应度值;  $t$  和  $t_{\max}$  分别为当前迭代次数和最大迭代次数。

## 2.2.3 跳出局部最优的策略

在寻优过程中, 粒子逐渐向全局最优位置逼近。当粒子位置和全局最优位置接近时, 式 (14) 的后 2 项接近 0, 式 (15) 中粒子的位置就无法有效更新, 种群将陷入停滞<sup>[20]</sup>, 为了避免出现停滞现象, 引入一种跳出局部最优的策略。首先引入了位置因子  $\gamma$  ( $\gamma \geq 0$ ), 其次构建粒子更新函数, 如式 (21) 和

式 (22) 所示。通过式 (22) 分析粒子到全局最优位置间距离与位置因子的关系, 判断该粒子是否需要解空间进行初始化。

$$\gamma = k \quad (21)$$

$$g(t) = \begin{cases} 0 & R(t) \geq \gamma \\ 1 & R(t) < \gamma \end{cases} \quad (22)$$

式中:  $k$  为常数, 通常来源于经验, 本文设定  $k=1$ ;  $R(t)$  为当前粒子与全局最优粒子的距离。  $g(t)=0$  表示该粒子不需要更新;  $g(t)=1$  表示该粒子需要在解空间进行初始化。由于粒子更新函数的特点, 使得算法在搜索阶段能维持粒子的活力, 避免粒子群陷入局部最优。

## 2.3 IPSO 算法复杂度

假定种群数目为  $N$ , 每个粒子的维度为  $d$ , 迭代次数为  $T$ 。PSO 算法的时间复杂度主要为粒子速度与位置的更新, 其时间复杂度为  $O(N \times d \times T)$ 。IPSO 算法与 PSO 算法的差异主要是采用了交叉策略和跳出局部最优策略, 交叉策略和跳出局部最优策略的时间复杂度分别为  $O(N \times d \times T)$  和  $O(N \times d \times T)$ , 与 PSO 算法的时间复杂度大致相同。

PSO 算法的空间复杂度主要为所有粒子的存储, 其空间复杂度为  $O(N \times d)$ 。IPSO 算法主要增加了当前粒子与全局最优粒子的距离  $[R(t)]$  和几个常数 (即文中的  $C$  和  $\gamma$ ) 存储, 其空间复杂度为  $O(N)$  和  $O(1)$ , 与 PSO 算法的空间复杂度大致相同。

## 2.4 构造模型

将预测部分和超参数优化部分融合, 构造出 IPSO-AM-LSTM 模型, 模型构造过程如下: ① 设定超参数的搜索范围, 在指定范围内随机生成初始种群, 获得超参数的初始配置, 并应用于预测模型中; ② 在训练集上训练模型预测部分, 得到预测结果; ③ 根据预测结果使用 IPSO 算法对超参数部分进行优化; ④ 判断是否满足终止条件, 若满足, 则输出最优的超参数配置。反之, 将③得到的超参数配置给预测部分, 返回步骤②。IPSO-AM-LSTM 模型的结构如图 4 所示。

## 2.5 模型的训练流程

IPSO-AM-LSTM 能耗预测模型的训练流程如图 5 所示, 具体训练流程如下:

1) 将样本数据按照 7:3 的比例进行划分, 得到训练集和测试集。

2) 使用归一化对数据进行预处理, 归一化公式如式 (23) 所示<sup>[15]</sup>。

$$X_e = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (23)$$

式中:  $x_{\max}$  与  $x_{\min}$  为样本数据中各变量的最大值与

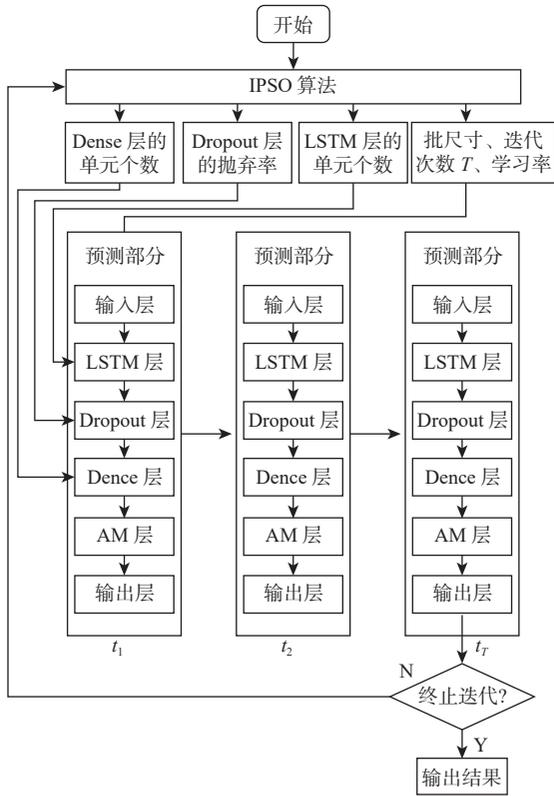


图 4 IPSO-AM-LSTM 结构示意图  
Fig. 4 Structure of IPSO-AM-LSTM

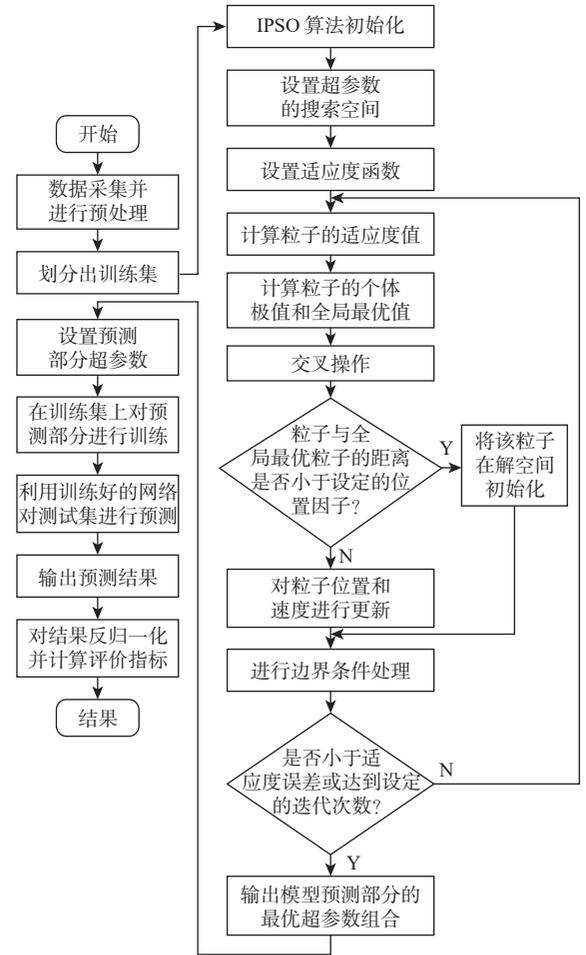


图 5 IPSO-AM-LSTM 训练流程  
Fig. 5 Training flow chart of IPSO-AM-LSTM

最小值;  $X_c$  为归一化后的数据;  $x$  为样本数据。

3) 选用预测部分中的批大小、学习率、LSTM 层单元数、Dropout 层丢弃概率、Dense 层单元数和迭代次数作为需要优化的超参数, 并设置各自的搜索范围。

4) 设置 IPSO 算法的种群大小  $N$ 、迭代次数  $T$  和粒子维度  $d$ 。

5) 初始化粒子的位置和速度, 在训练集上对预测部分进行训练, 选用预测值与真实值的均方误差为适应度函数, 并计算每个粒子的适应度值。

6) 根据粒子的适应度求得个体最优位置和全局最优位置。

7) 计算其他粒子与全局最优粒子间的欧氏距离  $R(t)$ , 根据式 (18) 判断粒子是否满足交叉条件。若满足, 则根据交叉策略对粒子进行交叉; 否则, 不对粒子进行交叉。

8) 根据式 (22), 判断  $R(t)$  是否小于位置因子  $R^2$ 。若小于, 则将该粒子在解空间重新初始化; 否则, 根据式 (14) 和式 (15) 直接更新粒子速度和位置。

9) 判断粒子适应度是否小于设定值或者迭代次数是否达到设定值。满足条件, 则退出 IPSO 算法; 否则, 继续迭代。

10) 将 IPSO 算法得出的全局最优位置分配给模型的预测部分, 并在训练集上进行训练。

- 11) 对测试集进行仿真, 输出预测结果。
- 12) 对预测结果反归一化, 与测试集中能耗数据进行对比, 并结合评价指标对模型进行分析。

### 3 实例分析

#### 3.1 数据来源

将采集到的夏季停靠在某机场, 使用地面空调为飞机客舱制冷的相关数据作为数据集。该飞机型号为 Boeing737-800, 使用制冷量为 150 kW 的地面空调对客舱温度和湿度进行调节。该数据共 300 组, 每组数据均包括乘客下机后的客舱温度和湿度、乘客登机时的客舱温度和湿度及该过程中地面空调的耗电量。将下机后客舱温度、下机后客舱湿度、登机时客舱温度、登机时客舱湿度作为模型的输入特征, 耗电量作为模型的输出。部分能耗数据如表 1 所示。

#### 3.2 评价指标

数据驱动模型的性能一般基于真实值和预测结果的统计指标进行评估。本文选择均方误差  $M_{SE}$ 、平均绝对误差比率  $M_{APE}$  及决定系数  $R_2$  作为评

表1 部分能耗数据

Table 1 Part of sample data

乘客下机的客舱温度/℃	乘客下机的客舱湿度/%	乘客登机的客舱温度/℃	乘客登机的客舱湿度/%	耗电量/kW
31.81	56.25	26.49	37.01	181.53
30.35	62.70	24.07	37.10	165.64
31.84	49.52	25.85	25.05	179.51
35.18	67.51	26.64	35.31	185.49
33.81	72.73	25.93	36.86	169.88

价指标,以评估模型对地面空调能耗预测精度<sup>[15]</sup>。计算过程如式(24)~式(26)所示。

$$M_{SE} = \frac{1}{m} \sum_{i=1}^m (y_i - f(x_i))^2 \quad (24)$$

$$M_{APE} = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{y_i - f(x_i)}{f(x_i)} \right| \quad (25)$$

$$R_2 = 1 - \frac{\sum_{i=1}^m (y_i - f(x_i))^2}{\sum_{i=1}^m (y_i - \bar{y}_i)^2} \quad (26)$$

式中:  $\bar{y}_i$ 为真实值的平均值;  $y_i$ 为真实值;  $f(x_i)$ 为预测值;  $m$ 为样本数。

### 3.3 超参数优化过程

提出的IPSO-AM-LSTM模型中的超参数包含批大小、学习率、LSTM层单元数、Dense层单元数、Dropout层丢弃概率和迭代次数,其配置结果决定着模型预测性能的优劣。本文设置的超参数搜索范围如表2所示。

表2 超参数搜索范围

Table 2 Search range of hyperparameters

超参数	搜索范围
批大小	1~90
学习率	0.000 1~0.01
LSTM层单元数	10~90
Dense层单元数	10~90
Dropout层丢弃概率	0.1~0.9
迭代次数	400

选取SCA-AM-LSTM、PSO-AM-LSTM和IPSO-AM-LSTM作为对比模型,在训练集上训练各模型的超参数。将迭代数目设为100,种群数目设为10。SCA、PSO和IPSO算法迭代过程的对比如图6所示。

从图6可以看出:SCA算法比PSO算法具有更好的搜索能力;IPSO算法的寻优能力要优于SCA算法和PSO算法。3种算法搜寻结果如表3所示。

### 3.4 仿真结果与分析

根据算法搜寻结果,对模型预测部分进行配

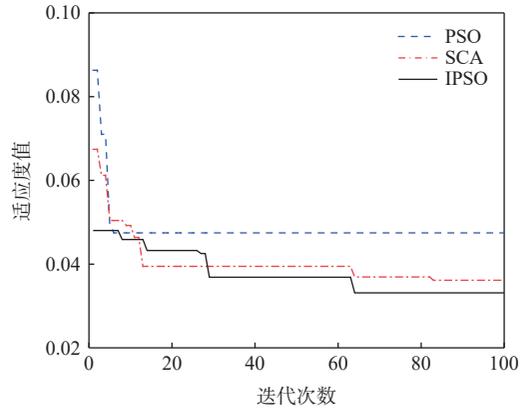


图6 优化算法迭代过程

Fig. 6 Iterative process of optimization algorithms

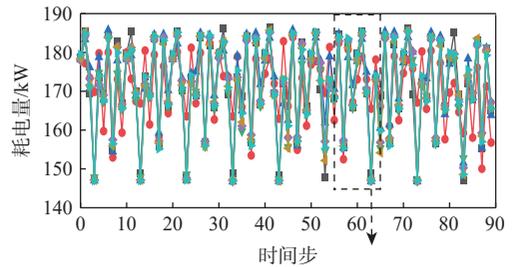
表3 3种算法搜寻结果

Table 3 Three algorithms search results

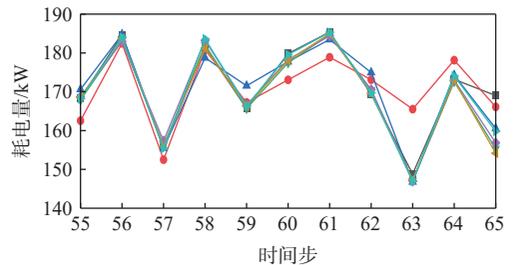
算法	批大小	LSTM层单元数	Dense层单元数	Dropout层丢弃概率	学习率	迭代次数
SCA	3	74	22	0.1	0.005 5	400
PSO	1	74	45	0.28	0.009 0	400
IPSO	1	23	37	0.1	0.003 5	400

置。在测试集上仿真,将仿真结果与按照经验调参的BP网络和LSTM网络的仿真结果进行对比,不同模型下预测值和真实值的对比曲线如图7所示。

为进一步研究IPSO-AM-LSTM模型的性能,在测试集上分别使用 $M_{SE}$ 、 $M_{APE}$ 和 $R_2$ 评价指标,不同模型评价结果如表4所示。



(a) 测试集预测结果与真实值对比



(b) 部分测试集预测结果与真实值对比



图7 不同模型下预测值与真实值的对比

Fig. 7 Comparison of predicted and real values under different models

表 4 不同模型评价结果

Table 4 Evaluation results for different models

模型	$M_{SE}$	$M_{APE}/\%$	$R_2$
BP	61.042	7.075	0.553
LSTM	14.691	1.669	0.893
AM-LSTM	10.195	1.140	0.925
PSO-AM-LSTM	8.952	1.087	0.935
SCA-AM-LSTM	7.519	0.840	0.945
IPSO-AM-LSTM	4.394	0.774	0.968

对不同模型的评价结果进行分析可以看出:

①IPSO-AM-LSTM 模型在评价指标上优于其他模型;②挖掘数据中的更多的时序信息,有助于提高模型精度;③利用算法对超参数进行优化比经验调参具有更高的预测精度;④SCA 算法比 PSO 算法能更有效地获得全局最优解;⑤IPSO 算法比 SCA 算法和 PSO 算法具有更强的搜索能力,可以更好地解决 LSTM 网络超参数难以选取的问题。

## 4 结 论

为提升飞机客舱使用地面空调制冷时地面空调能耗预测精度,将 LSTM 神经网络、注意力机制和 IPSO 算法进行融合,建立了 IPSO-AM-LSTM 模型,并对仿真结果进行分析,得到以下结论:

1) 提出 2 种优化方法来改进 PSO 算法,一种是基于欧氏距离的交叉策略,另一种是构建迭代次数与粒子适应度相结合的惯性权重函数。将这 2 种优化方法与跳出局部最优策略相结合对粒子进行更新,从而提出了 IPSO 算法。

2) IPSO-AM-LSTM 相比 BP、LSTM、AM-LSTM、PSO-AM-LSTM 以及 SCA-AM-LSTM 对飞机地面空调的能耗预测,在预测精度和决定系数上均有明显的提高。

3) 增强模型对数据中时序信息的提取和利用可以提高飞机地面空调能耗预测精度。

## 参考文献 (References)

[1] SHI G, LIU D R, WEI Q L. Energy consumption prediction of office buildings based on echo state networks[J]. Neurocomputing, 2016, 216: 478-488.

[2] WANG J Q, DU Y, WANG J. LSTM based long-term energy consumption prediction with periodicity[J]. Energy, 2020, 197: 117197.

[3] WANG Z Y, WANG Y R, ZENG R C, et al. Random Forest based hourly building energy prediction[J]. Energy and Buildings, 2018, 171: 11-25.

[4] 王修岩, 刘艳敏, 张革文, 等. 基于 PSO 和 CRO 联合算法的飞机客舱能耗预测[J]. 系统仿真学报, 2018, 30(8): 3074-3081.

WANG X Y, LIU Y M, ZHANG G W, et al. Prediction of aircraft cabin energy consumption based on PSO and CRO algorithms[J].

Journal of System Simulation, 2018, 30(8): 3074-3081(in Chinese).

[5] 林家泉, 孙凤山, 李亚冲, 等. 基于 IPSO-Elman 神经网络的飞机客舱能耗预测[J]. 航空学报, 2020, 41(7): 234-243.

LIN J Q, SUN F S, LI Y C, et al. Prediction of aircraft cabin energy consumption based on IPSO-Elman neural network[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(7): 234-243(in Chinese).

[6] BEDI G, VENAYAGAMOORTHY G K, SINGH R. Development of an IoT-driven building environment for prediction of electric energy consumption[J]. IEEE Internet of Things Journal, 2020, 7(6): 4912-4921.

[7] SRIVASTAVA S, LESSMANN S. A comparative study of LSTM neural networks in forecasting day-ahead global horizontal irradiance with satellite data[J]. Solar Energy, 2018, 162: 232-247.

[8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[9] RAJAN S, CHENNIAPPAN P, DEVARAJ S, et al. Novel deep learning model for facial expression recognition based on maximum boosted CNN and LSTM[J]. IET Image Processing, 2020, 14(7): 1373-1381.

[10] JO J, KUNG J, LEE Y. Approximate LSTM computing for energy-efficient speech recognition[J]. Electronics, 2020, 9(12): 2004.

[11] LIU S C, WANG X L, XIANG Y, et al. Multi-channel fusion LSTM for medical event prediction using EHRs[J]. Journal of Biomedical Informatics, 2022, 127: 104011.

[12] SEYEDZADEH S, POUR RAHIMIAN F, RASTOGI P, et al. Tuning machine learning models for prediction of building energy loads[J]. Sustainable Cities and Society, 2019, 47: 101484.

[13] KIM T Y, CHO S B. Predicting residential energy consumption using CNN-LSTM neural networks[J]. Energy, 2019, 182: 72-81.

[14] MA C, LIN C, SAMUEL O W, et al. Continuous estimation of upper limb joint angle from sEMG signals based on SCA-LSTM deep learning approach[J]. Biomedical Signal Processing and Control, 2020, 61: 102024.

[15] 周璇, 林家泉. 基于改进长短期记忆网络的地面空调能耗预测[J]. 北京航空航天大学学报, 2023, 49(10): 2750-2760.

ZHOU X, LIN J Q. Prediction of ground air conditioner energy consumption based on improved long short-term memory network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(10): 2750-2760(in Chinese).

[16] REN X Q, LIU S L, YU X D, et al. A method for state-of-charge estimation of lithium-ion batteries based on PSO-LSTM[J]. Energy, 2021, 234: 121236.

[17] WANG D S, TAN D P, LIU L. Particle swarm optimization algorithm: an overview[J]. Soft Computing, 2018, 22(2): 387-408.

[18] 梅海涛, 华继学, 王毅, 等. 基于直觉模糊支配的混合多目标粒子群算法[J]. 计算机科学, 2017, 44(1): 253-258.

MEI H T, HUA J X, WANG Y, et al. Hybrid multi-objective particle swarm optimization based on intuitionistic fuzzy dominance[J]. Computer Science, 2017, 44(1): 253-258(in Chinese).

[19] 汪浩然, 夏克文, 牛文佳. 分段正交匹配追踪 (StOMP) 算法改进研究[J]. 计算机工程与应用, 2017, 53(16): 55-61.

WANG H R, XIA K W, NIU W J. Improved research on stagewise orthogonal matching pursuit (StOMP) algorithm[J]. Computer Engineering and Applications, 2017, 53(16): 55-61(in Chinese).

- [20] HAN F, SUN Y W T, LING Q H. An improved multiobjective search strategy and circular transposon mechanism[J]. Complexity, quantum-behaved particle swarm optimization based on double 2018, 2018(1): 8702820.

## Energy consumption prediction of aircraft ground air conditioning based on IPSO-AM-LSTM

LIU Han, LIN Jiaquan\*

(College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** As a complex thermal system, the energy consumption of aircraft ground air conditioning is affected by many factors, including various weather data and time characteristics. In order to improve the prediction accuracy of ground air conditioning energy consumption when the aircraft cabin is cooled by ground air conditioning, a ground air conditioning energy consumption prediction model based on a long-short-term memory (LSTM) network is proposed. The prediction component of the model, which is utilized to extract and make use of the time series information in the data, is built by integrating the long-short-term memory network with the attention mechanism. The prediction accuracy is used as the fitness function of the algorithm. The hyperparameter optimization based on the improved particle swarm optimization (IPSO) algorithm is proposed. Compared with the standard particle swarm optimization (PSO) algorithm, the improved particle swarm optimization algorithm combines the number of iterations with the fitness to construct a dynamic adjustment function of the inertia weight. The distance from the particle to the global most optimal position is introduced and a particle intersection strategy is proposed to improve the diversity of particle swarms. The mean square error of the prediction result is 4.394. The mean absolute percentage error is 0.774%, and the coefficient of determination is 0.968. The results indicate that the prediction approach has a greater accuracy when compared to other prediction methods.

**Keywords:** aircraft cabin; ground air condition; energy consumption prediction; particle swarm optimization; LSTM neural network