航 空 学 报
Acta Aeronautica et Astronautica Sinica
Jul. 25 2020 Vol. 41 No. 7
ISSN 1000-6893 CN 11-1929/V

http://hkxb.buaa.edu.cn hkxb@buaa.edu.cn

引用格式：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)：323614. 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)：323614 (in Chinese). doi：10.7527/S1000-6893.2020.23614

基于IPSO-Elman神经网络的飞机客舱能耗预测

林家泉[1,*]，孙凤山[1]，李亚冲[1]，庄子波[2]

1. 中国民航大学 电子信息与自动化学院，天津 300300
2. 中国民航大学 飞行学院，天津 300300

摘 要：为了提高飞机客舱使用地面空调制冷时客舱能耗的预测精度，提出了一种改进的粒子群优化(IPSO)Elman神经网络的飞机客舱能耗预测模型。依据对算法中惯性权重与学习因子的收敛域分析，得出了二者合理的取值范围，将粒子到全局最优位置间距离与参数的取值范围相结合，构造了惯性权重与学习因子的动态调节函数，对其进行非线性的动态调节，并引入了变异因子，提出了一种跳出局部最优的策略，防止粒子群优化(PSO)陷入局部最优。将IPSO-Elman应用于Boeing738飞机客舱能耗预测中，与PSO-Elman、Elman算法进行性能比较，仿真结果表明基于IPSO-Elman的客舱能耗预测模型在预测精度和收敛速度方面均有一定的提升。该研究结果为飞机客舱能耗预测模型的建立提供了理论依据，对飞机地面空调的节能与机场电能合理调配提供了支持。

关键词：飞机客舱；地面空调；能耗预测；粒子群优化；Elman神经网络

中图分类号：V219 **文献标识码**：A **文章编号**：1000-6893(2020)07-323614-10

随着节能减排的规划逐步推进，民航设备的节能减排也受到越来越多的关注。在夏季，飞机停靠在机场时，大部分航空公司均采用飞机地面空调设备为客舱制冷[1]，准确预测出客舱的能耗需求，是达到地面空调节能以及保证客舱热舒适性的关键，也有助于机场电能的合理分配。同时，由于地面空调采用恒速的送风策略，当地面空调送风速度过小时，不满足客舱热舒适性要求，当地面空调送风速度过大时，浪费能源。因此，若能准确地预测客舱的能耗，通过计算能够得出既满足热舒适性又节能的地面空调的最优送风速度，则能为地面空调的送风控制提供理论依据。地面空调为客舱制冷如图1所示。影响客舱能耗的主要因素为天气因素与客舱内部因素，天气因素主要包括室外温度、湿度、太阳辐射强度、降水量等，客舱内部因素主要包括客舱内的温度、湿度、风速等[2]。

人工神经网络方法广泛地运用于建立非线性数据间的关系，以达到预测的目的[3]。文献[4]提出基于改进的遗传算法用于优化极限学习机网络的航空发动机轴承故障预测模型，文献[5]提出将人工神经网络运用于建筑物能耗预测中，取得了较为理想的效果。文献[6]提出基于小波神经网络，运用于飞机客舱能耗预测中，建立了飞机客舱能耗预测模型。综上可知，由于影响客舱能耗的因素间也存在着这种非线性特性，在采集到的样本数据充足的情况下，依据神经网络建立客舱能耗预测模型理论上是可行的。

Elman神经网络采用梯度下降的学习规则，存在容易陷入局部最优且收敛速度慢的问题。有

收稿日期：2019-10-30；**退修日期**：2019-11-19；**录用日期**：2020-02-01；**网络出版时间**：2020-02-07 09:28
网络出版地址：http://hkxb.buaa.edu.cn/CN/html/20200719.html
基金项目：国家自然科学基金委员会-中国民航局联合基金(U1433202)
* **通信作者**. E-mail：jqlin@cauc.edu.cn

学者提出使用标准的粒子群优化(PSO)算法优化Elman神经网络[7],但实验结果显示,基于标准的PSO优化后的Elman神经网络,仍然存在精度不佳的问题。因此,需要对PSO算法进行改进。改进PSO算法能够通过调节算法的惯性权重与学习因子实现。文献[8]通过调节PSO算法中的学习因子 c_1 和 c_2,c_1 随着迭代次数的增加进行线性递减变化,c_2 随着迭代次数的增加进行线性递增变化,增强了算法搜索能力,使得寻优精度得到提高。文献[9]提出一种惯性权重的非线性递减调节,加快了算法的寻优速度。文献[10]提出了一种基于全局最优位置对惯性权重进行动态调节的方法,改进了PSO算法。文献[11]提出了一种基于粒子聚集程度的惯性权重动态调节方式,在一定程度上避免了算法陷入局部最优。文献[12]通过结合粒子的适应度对惯性权重进行动态调节,提高了算法的精度。

仅单一调节学习因子或惯性权重,并未考虑惯性权重与学习因子之间的配合作用,则不能建立粒子的局部搜索能力与全局搜索能力的动态平衡[13]。因此,为使得PSO算法得到更大程度的优化,本文考虑了2个参数之间的配合,基于参数的收敛域,提出了基于粒子到全局最优位置的距离对惯性权重与学习因子进行动态调节,构造了两者的动态调节函数,同时,引入了变异因子,提出了跳出局部最优的策略,避免PSO算法过早收敛,使得PSO算法得到改进,提高了PSO算法的收敛速度与精度。将IPSO算法与Elman神经网络相结合,通过IPSO算法的全局最优位置对Elman神经网络的权值与阈值进行更新,将IPSO-Elman应用于对Boeing738飞机客舱进行能耗预测,用以准确预测出飞机客舱的能耗并缩短预测耗时。



图1 地面空调系统

Fig. 1 Ground air condition system

1 Elman神经网络和PSO算法

1.1 Elman神经网络

Elman神经网络是在BP(Back Propagation)神经网络上增加一个承接层使得网络对历史数据具有短期记忆功能,增强了其处理动态数据的能力[14]。Elman神经网络结构如图2所示。

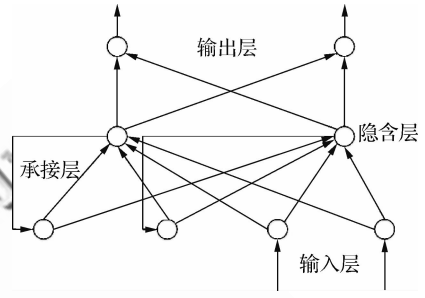


图2 Elman神经网络结构

Fig. 2 Structure of Elman neural network

Elman神经网络的模型为

$$x_c(t) = a x_c(t-1) - x(t-1) \tag{1}$$

$$x(t) = g(W_1 x_c(t) + W_2 u(t-1)) \tag{2}$$

$$y(t) = f(x(t) W_3) \tag{3}$$

式中:$u(t-1)$ 为神经网络的输入;$x(t)$ 为隐含层输出;$x_c(t)$ 为隐含层向承接层的输入;W_1、W_2、W_3 分别为承接层到隐含层、输入层到隐含层、隐含层到输出层的权值;t 表示迭代计算到第 t 步;$y(t)$ 为神经网络输出;$g(*)$ 为隐含层传递函数;$f(*)$ 为输出神经元的激励函数。

Elman神经网络的误差函数为

$$E(t) = \sum_{i=1}^{m} [y_i(t) - e_i(t)]^2 \tag{4}$$

式中:$e_i(t)$ 为期望输出;m 为样本总数;i 为第 i 个样本。

1.2 PSO算法

PSO算法受鸟群搜寻食物行为的影响而产生[15],影响鸟群中的鸟搜寻食物主要有2个因素:鸟飞行的速度、鸟和食物之间的距离。同样,将鸟群中的鸟视为粒子群中的粒子,搜寻食物的过程视为粒子搜寻最优解的过程。

每一个粒子均有速度和位置2个属性,在每次迭代计算中,每个粒子在 K 维空间下,以一定

的速度和位置在搜寻最优解，将搜寻到自己的最优解所处位置记为个体极值，其中 $V_i=\{V_{i1},V_{i2},\cdots,V_{ik}\}$ 为第 i 个粒子速度，$x_i=\{x_{i1},x_{i2},\cdots,x_{ik}\}$ 为第 i 个粒子位置，$P_{\text{best}i}=\{P_{\text{best}i1},P_{\text{best}i2},\cdots,P_{\text{best}ik}\}$ 为第 i 个粒子的个体极值。

假设目标函数为 $f_g(x)$，第 i 个个体极值的计算式为[16]

$$P_{\text{best}i}=\begin{cases}P_{\text{best}i}(t) & f_g(x(t+1))\geqslant f_g(P_{\text{best}i}(t))\\ x(t+1) & f_g(x(t+1))<f_g(P_{\text{best}i}(t))\end{cases} \tag{5}$$

将个体极值与粒子群中的其他极值共享，选出最优的个体极值做为全局最优位置 $g_{\text{best}}(t)$。假设粒子群中含有 N 个粒子，迭代次数为 t，$g_{\text{best}}(t)$ 的求解过程为

$$G_{\text{best}}(t)=\min\{f_g(P_{\text{best}\,1}(t)),f_g(P_{\text{best}2}(t)),\cdots,f_g(P_{\text{best}\,N}(t))\} \tag{6}$$

若 $f_g(P_{\text{best}i}(t))=G_{\text{best}}(t)$，则有 $g_{\text{best}}(t)=P_{\text{best}j}(t)$，$G_{\text{best}}(t)$ 为全局最优位置对应的适应度函数值。

每个粒子通过全局最优位置来调整其位置和速度。粒子的速度与位置计算公式为

$$V_{ij}(t+1)=\omega V_{ij}(t)+c_1r_1[P_{\text{best}\,ij}(t)-x_{ij}(t)]+c_2r_2[g_{\text{best}\,j}(t)-x_{ij}(t)] \tag{7}$$

$$x_{ij}(t+1)=x_{ij}(t)+V_{ij}(t+1) \tag{8}$$

式中：i 为粒子群的粒子个数，$i=1,2,\cdots,N$；j 为搜索空间的维数，$j=1,2,\cdots,K$；$V_{ij}(t)$ 为迭代 t 次后，粒子的速度；$x_{ij}(t)$ 为迭代 t 次后，粒子所在的位置；$P_{\text{best}\,ij}$ 为第 i 个粒子的个体极值的 j 维值；$g_{\text{best}\,j}$ 为全局最优位置的 j 维值；r_1 与 r_2 为[0，1]上的随机数；c_1、c_2 为学习因子；ω 为惯性权重。

2 IPSO 算法优化 Elman 神经网络

2.1 粒子与全局最优间的距离

PSO 算法中，粒子的位置更新与速度更新取决于全局最优位置，当粒子与全局最优位置的距离较大时，粒子分布分散，有助于粒子的全局搜索，粒子分布集中，有助于粒子的局部搜索。因此，粒子与全局最优位置之间的距离是学习因子与惯性权重动态调节过程中的重要因素，在第 t 次迭代中，每个粒子与当前全局最优位置之间的距离 $R(t)$ 的计算公式为

$$R(t)=\sqrt{(x_{i1}(t)-g_{\text{best}1}(t))^2+\cdots+(x_{ij}-g_{\text{best}j}(t))^2} \tag{9}$$

2.2 基于 $R(t)$ 的惯性权重及学习因子动态调节

单一调节粒子群的惯性权重或学习因子，很难使粒子群算法达到最佳效果，需要进行惯性权重与学习因子的共同调节。

在 PSO 算法中惯性权重 ω 影响了粒子群的粒子搜索能力，当 ω 较大时，全局搜索能力强，更容易定位到全局最优解的大体位置，ω 较小时，局部搜索能力强，更容易逼近全局最优解。研究结果表明对惯性权重随着迭代次数的增加进行递减的动态调节方式有助于加快算法的收敛速度与提升精度[17]。为了进一步改善 PSO 算法的收敛速度与精度，引入每个粒子与当前全局最优位置之间的距离 $R(t)$，即第 t 次迭代中，每个粒子与当前全局最优位置之间的距离 $R(t)$。利用 $R(t)$ 在寻优前期较大、在寻优后期较小的特点，提出了一种结合 $R(t)$、ω 随着迭代次数的增加进行非线性递减的动态调节方法，使 ω 在迭代寻优的前期拥有较大的值，快速最优解的位置，使 ω 在迭代寻优的后期，拥有较小的值，更快逼近最优解，所构造的 ω 动态调节函数如式(10)所示，对 ω 的动态调节过程如图 3 所示。本文 ω 的取值范围为[0.4，0.9][18]。

$$\omega(t)=\omega_{\min}+(\omega_{\max}-\omega_{\min})\cdot\frac{\cos\left(1-\dfrac{R(t)}{R_{\max}}\right)\cdot\dfrac{t}{t_{\max}}\cdot\pi+1}{2} \tag{10}$$

式中：$t_{\max}$ 为 t 的最大迭代次数；$\omega_{\max}$ 为惯性权重的最大值；$\omega_{\min}$ 为惯性权重的最小值；$R_{\max}$ 为粒子与全局最优位置的距离最大值；$\omega(t)$ 为第 t 步惯性权重的值。

在 PSO 算法中学习因子 c_1、c_2 影响了粒子群中粒子寻找最优解的运动轨迹，c_1 决定粒子的个体认知能力，c_1 取值越大算法搜索全局最优解越依靠个体极值，c_2 决定粒子的社会认知能力，c_2 取值越大算法搜索全局最优解越依靠群体最优位置。利用 $R(t)$ 在寻优前期较大、在寻优后期较小的特点，提出了一种结合 $R(t)$、c_1 随着迭代次数

的增加进行非线性递减的动态调节方法，一种结合 $R(t)$、c_2 随着迭代次数的增加进行非线性递增的动态调节方法。所构造的 c_1、c_2 的动态调节函数如式(11)和式(12)所示，c_1、c_2 的动态调节过程如图 4 所示。

$$c_1(t) = c_{1\min} + (c_{1\max} - c_{1\min}) \cdot \frac{\cos\left(1 - \dfrac{R(t)}{R_{\max}}\right) \cdot \dfrac{t}{t_{\max}} \cdot \pi + 1}{2} \tag{11}$$

$$c_2(t) = 2.8 - c_1(t) \tag{12}$$

式中：$c_{1\min}$为学习因子 c_1 的最小值；$c_{1\max}$为学习因子 c_1 的最大值；$c_{2\min}$为学习因子 c_2 的最小值；$c_{2\max}$为学习因子c_2的最大值；$c_1(t)$为第t步学习因子

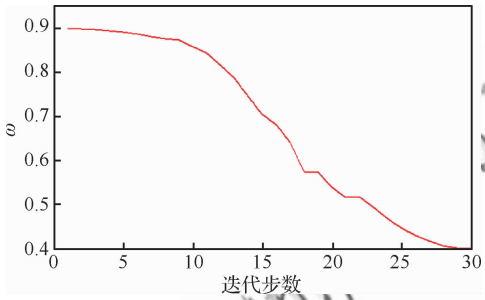


图 3 惯性权重调节过程

Fig. 3 Adjustment process of inertia weight

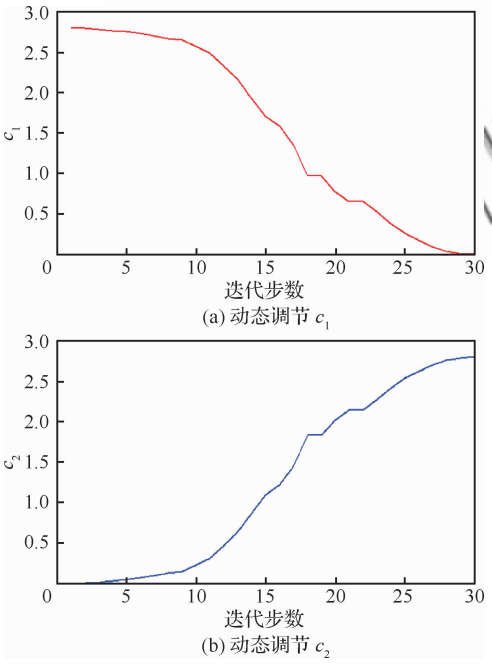


图 4 学习因子调节过程

Fig. 4 Adjustment process of learning factors

c_1 的值；$c_2(t)$为第 t 步学习因子 c_2 的值。

根据文献[15]得出了 PSO 算法的 ω 与 c_1、c_2 的收敛域，其中 $0<c_1+c_2<2\omega+2$，$\omega<1$，为使得 PSO 算法具有较好的收敛性，c_1、c_2 的取值范围应在收敛域内。本文 ω 的取值范围为[0.4,0.9]，依据式(10)、式(12)，结合学习因子的收敛域，得出合理的 c_1 取值范围为(0,2.8)，c_2 取值范围为(0,2.8)。

2.3 跳出局部最优的策略

为了避免 PSO 算法的过早收敛现象，提出了一种跳出局部最优的策略。依据遗传算法中的变异思想，引入了变异因子，通过分析粒子的聚集程度与变异因子的关系，构造了全局位置的更新函数，使得算法跳出局部最优。聚集程度的判定公式为[19]

$$\sigma^2 = \sum_{i=1}^{N}\left(\frac{f_i - f_{\text{avg}}}{n}\right)^2 \tag{13}$$

式中：N 为粒子群中粒子的个数；，f_i 为第 i 个粒子的适应度；f_{avg}为当前粒子群的平均适应度；σ^2 为粒子群的聚散程度；n 为归一化定标因子。

设定变异因子 s 的值为 0.1，迭代计算至第 t 步，当 $\sigma^2 < s$ 时，则对当前全局最优位置 $g_{\text{best}}(t)$进行更新，本文所提出的更新公式为

$$g_{\text{best}}(t) = g_{\text{best}}(t)(\sigma^2 r + 1) \tag{14}$$

式中：r 为[0,1]之间的随机数。

2.4 IPSO-Elman 神经网络

利用 IPSO 算法得到的全局最优位置作为 Elman 算法的最优权值与阈值，使得 Elman 神经网络得到优化，IPSO-Elman 的流程图如图 5 所示。IPSO-Elman 神经网络的步骤如下：

1) 样本数据归一化，确定 Elman 神经网络的网络结构，建立 Elman 神经网络。

2) 初始化粒子的速度、位置、惯性权重、加速因子及迭代次数。

3) 计算粒子的适应度，粒子的适应度定义为

$$f = \sum_{i=1}^{m}[y_i(t) - e_i(t)]^2 \tag{15}$$

4) 根据粒子的适应度值求得个体最优位置与全局最优位置。

5) 计算粒子群的聚集程度，若聚集程度的值

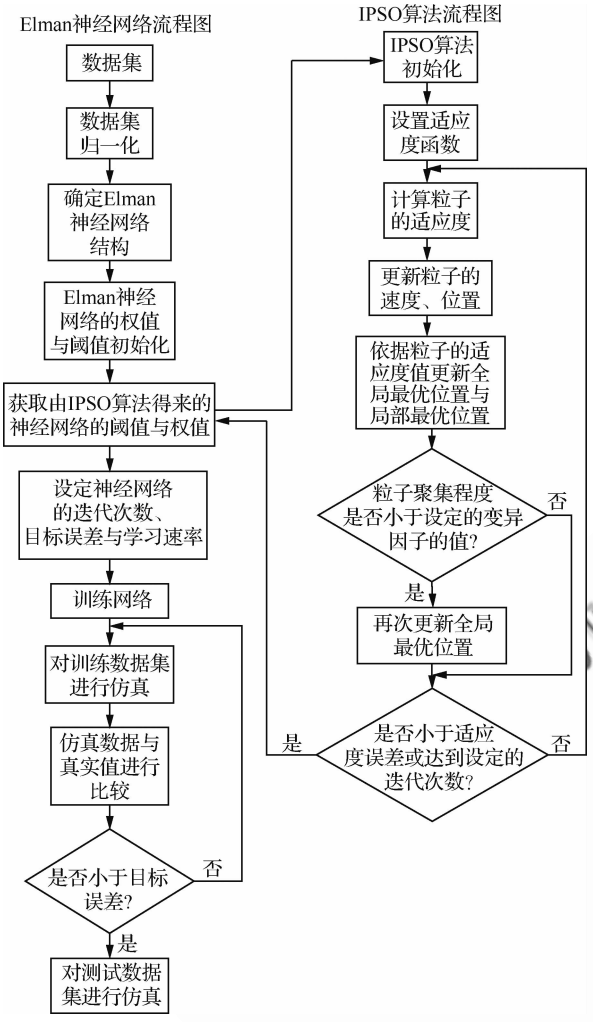


图 5 IPSO-Elman 算法流程图

Fig. 5 Flow chart of IPSO-Elman algorithm

小于变异因子的值，则根据式(14)更新当前全局最优位置，否则不对当前全局最优位置进行改变。

6) 根据式(10)～式(12)对学习因子与惯性权重进行动态调节，避免 PSO 陷入局部最优，加快算法迭代速度。

7) 判断粒子适应度是否小于设定值或达到最大迭代次数，满足条件，则退出 PSO 算法，否则返回步骤 3)，继续计算粒子适应度。

8) 依据 Elman 神经网络的网络结构，将 IPSO 得到的全局最优位置分配给 Elman 神经网络作为其最优阈值与最优权值，利用样本数据进行网格训练。

9) 当网格训练的误差小于设定值时，结束训练，对测试数据进行仿真。

3 飞机客舱能耗预测

3.1 数据来源

为了达到客舱能耗预测的目的，需要建立影响客舱热舒适性的主要因素与客舱能耗之间的关系，影响客舱热舒适性的主要因素为客舱温度与湿度[20]。因此，为建立飞机客舱能耗的预测模型，采集了夏季停靠在某机场，使用地面空调制冷的 Boeing738 飞机客舱能耗数据，包括乘客下机后的客舱温度和湿度，乘客登机时到达客舱热舒适性要求的客舱温度和湿度以及飞机客舱的耗电量。研究飞机客舱能耗的阶段为当上一批乘客下机完成，使用地面空调对飞机客舱进行制冷，在下一批乘客登机时为止。共采集 300 组能耗数据，部分采集数据如表 1 所示。

表 1 部分样本数据

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
32.81	72.68	24.75	36.37	169.44
30.36	61.86	26.18	35.35	147.11
30.59	63.81	24.63	33.34	168.21
32.98	51.18	22.98	36.55	183.79
32.12	56.34	24.74	36.62	181.78

3.2 数据归一化处理

为消除样本数据中奇异样本数据的影响，需要对样本数据进行归一化：

$$d' = 2 \times \frac{d_{\max} - d_{\min}}{d_{\max} - d_{\min}} - 1 \tag{16}$$

式中：$d_{\max}$ 与 $d_{\min}$ 为样本数据中的最大值与最小值；d' 为归一化后的样本数据。

3.3 Elman 神经网络结构的建立

Elman 神经网络是在 BP 神经网络上增加了一个承接层，以达到记忆的目的，使得其对历史数据更加敏感，相比于 BP 神经网络具有更强的计算能力，而能耗预测模型的训练与验证依靠历史数据。因此，为准确预测出客舱能耗，选择 Elman 神经网络建立飞机客舱能耗预测模型。在获取了实验数据后，需要建立能够用于研究实验数据的

http://hkxb.buaa.edu.cn

神经网络。由于地面空调能耗产生的原因是为客舱制冷除湿,以达到乘客的热舒适性要求,而影响客舱热舒适性的主要因素为温度与湿度,两者具有较强的耦合性且对于客舱能耗的影响较大,故选择乘客下机后的客舱的温度和湿度,乘客登机时达到客舱热舒适性要求的客舱温度和湿度作为预测模型的输入数据,飞机客舱的能耗量为输出数据。共计 4 种输入数据、1 种输出数据,因此,得出 Elman 神经网络的输入层为 4 个节点,输出层成为 1 个节点,隐含层节点数的计算公式为[21]

$$H = \sqrt{m_{\text{in}} + n_{\text{out}}} + a \tag{17}$$

式中:m_{in}为输入层节点数;n_{out}为输出层节点数;a为 0～9 之间的常数。

为判断出 H 的取值对 Elman 神经网络性能的影响,得出 H 的最佳值,根据 H 的取值范围[3,12],建立了含有不同 H 的 Elman 神经网络。依据飞机客舱能耗的实验数据,进行 50 次仿真实验,每次仿真实验进行 1 000 次迭代运算,得出 H 值不同时 Elman 神经网络的平均误差,如表 2 所示。

由表 2 可知,当 $H=10$ 时,Elman 神经网络预测值与实际值的平均误差最小,故 Elman 神经网络隐含层的节点数 H 取 10。同时,由于 Elman 神经网络承接层的节点数应该与隐含层一致,故承接层的节点数也为 10。

表 2 Elman 神经网络的平均误差

Table 2 Average error of Elman neural network

H	平均误差
3	4.191 8
4	3.835 2
5	4.100 7
6	4.125 3
7	4.028 5
8	4.090 2
9	4.110 9
10	3.298 1
11	4.018 2
12	4.133 1

3.4 IPSO 算法参数设置

由于设定 Elman 神经网络的输入层节点数为 4,隐含层节点为 10,承接层节点数为 10,输出层节点数为 1。所以,IPSO 的维数为 161,粒子个数为[22]

$$N = \text{int}(10 + 2\sqrt{D}) \tag{18}$$

式中:D 为 IPSO 的维数;int(·)为向下取整。

3.5 Elman 神经网络最优权值与阈值的获取

IPSO 的维数为 161,则存放全局最佳位置的矩阵为 1×161。而 Elman 神经网络输入层到隐含层的权值矩阵为 10×4 的矩阵,共计 40 个权值,隐含层到承接层权值矩阵为 10×10 的矩阵,共计 100 个权值,隐含层的阈值矩阵为 10×1 的矩阵,共计 10 个阈值,隐含层到输出层的权值矩阵为 1×10 的矩阵,共计 10 个权值,输出层的阈值矩阵为 1×1 的矩阵,共计 1 个阈值。因此,将全局最优位置中的前 40 个元素分配作为神经网络输入层到隐含层的最优权值,第 41～140 个元素分配作为隐含层到承接层的最优权值,第141～150 个元素分配作为神经网络隐含层的最优阈值,将第 151～160 个元素分配作为神经网络隐含层到输出层的最优权值,将第 161 个元素分配作为神经网络输出层的最优阈值。

4 算法验证

为验证 IPSO-Elman 神经网络的预测精度以及收敛速度,进行了 IPSO-Elman 神经网络的编程,建立了 Boeing738 飞机客舱能耗预测模型。同时,与 Elman 神经网络、PSO-Elman 神经网络进行对比。其中总的数据集为 300 组能耗数据,随机选择 290 组数据作为训练数据,验证数据为 10 组,利用该方法对模型进行了验证。设定粒子群个数为 35,网络结构为 4-10-10-1 的 Elman 神经网络,PSO-Elman 依据参数设定标准[23]设定学习因子 c_1 为 2.05、c_2 为 0.5,每种方法均进行 50 次独立的仿真实验,每次仿真中 IPSO 算法进行 200 次迭代计算,Elman 神经网络算法进行 1 000次迭代计算,以预测模型跳出局部最优所需要的迭代次数为评判收敛速度快慢的标准。以预测结果与真实值之间的相对误差的平均值作为模型精度优劣的评判指标,相对误差的计算公式为[24]

http://hkxb.buaa.edu.cn
http://hkxb.buaa.edu.cn

$$\mathrm{RPE}=\left|\frac{u_{pi}-u_{ti}}{u_{ti}}\right|\times 100\% \tag{19}$$

式中：u_{pi}为第 i 个预测值；u_{ti}为第 i 个真实值。

在预测模型的训练函数、隐含层传递函数、输出层传递函数以及相对误差方面，对 3 种不同飞机客舱预测模型进行综合分析与对比，所得结果的比较如表 3 所示。其中常用的训练函数包括：traingd、trainlm、traingda、traingdx，隐含层常用的传递函数包括：logsig、tansig、radbas、tribas。常用的输出层传递函数为 purelin。

由表 3 能够得出，基于 IPSO-Elman 的飞机客舱能耗预测模型，选择训练函数为 trianlm，传递函数为tansig、purelin 时，其最小相对误差仅为 0.06%，相比于其他 2 种预测模型，预测精度有了一定的提升。依据表 3 分析能够得出训练函数以及传递函数的选取极大地影响了预测结果，当基于 IPSO-Elman 的飞机客舱能耗预测模型选择训练函数为 traingda，传递函数为 radbas、purelin 时，其最小相对误差为 1.35%，预测误差大大提高，因此，使用神经网络对不同数据集进行预测研究时，分析出适合该数据集的训练函数与传递函数是至关重要的。同时，当训练函数选择 traingd，传递函数选择 radbas、purelin 时，PSO-Elman 能耗预测模型的预测精度不如 Elman 能耗预测模型，可知，由于 PSO 算法自身也存在着容易陷入局部最优的特点，导致标准的 PSO 优化 Elman 神经网络的效果不佳，因此，对标准 PSO

表 3 不同模型的预测结果对比

Table 3 Predictive results comparison of different models

训练函数	传递函数	方法	最小相对误差/%	平均相对误差/%	最大相对误差/%
traingd	tansig，purelin	Elman	1.83	1.95	2.09
		PSO-Elman	1.15	1.52	1.82
		IPSO-Elman	0.64	0.89	1.12
	logsig，purelin	Elman	1.99	2.34	2.78
		PSO-Elman	1.29	1.43	1.87
		IPSO-Elman	1.08	1.13	1.38
	radbas，purelin	Elman	1.72	1.80	2.03
		PSO-Elman	1.52	1.65	1.93
		IPSO-Elman	1.21	0.95	0.83
	tribas，purelin	Elman	1.95	2.53	4.16
		PSO-Elman	1.34	1.87	2.21
		IPSO-Elman	1.19	1.34	1.57
trianlm	tansig，purelin	Elman	0.67	1.03	1.71
		PSO-Elman	0.21	0.39	0.95
		IPSO-Elman	0.06	0.14	0.22
	logsig，purelin	Elman	1.42	1.81	2.03
		PSO-Elman	0.77	1.05	1.31
		IPSO-Elman	0.26	0.31	0.45
	radbas，purelin	Elman	0.76	1.08	1.65
		PSO-Elman	0.68	1.02	1.56
		IPSO-Elman	0.39	0.46	0.54
	tribas，purelin	Elman	1.56	1.83	2.22
		PSO-Elman	0.63	0.92	1.18
		IPSO-Elman	0.32	0.40	0.86
traingda	tansig，purelin	Elman	2.05	2.32	2.53
		PSO-Elman	1.25	1.47	1.88
		IPSO-Elman	0.96	1.06	1.21
	logsig，purelin	Elman	1.89	2.04	2.31
		PSO-Elman	1.53	1.87	2.09
		IPSO-Elman	0.87	0.92	0.98
	radbas，purelin	Elman	1.47	1.59	1.86
		PSO-Elman	1.51	1.57	1.79
		IPSO-Elman	1.35	1.46	1.78
	tribas，purelin	Elman	1.83	1.91	2.09
		PSO-Elman	1.51	1.72	1.99
		IPSO-Elman	1.05	1.18	2.08
traingdx	tansig，purelin	Elman	0.78	1.12	1.46
		PSO-Elman	0.56	0.93	1.22
		IPSO-Elman	0.43	0.51	0.67
	logsig，purelin	Elman	2.33	2.37	2.45
		PSO-Elman	0.98	1.26	1.73
		IPSO-Elman	0.74	0.83	0.99
	radbas，purelin	Elman	1.27	1.44	1.83
		PSO-Elman	1.39	1.61	1.96
		IPSO-Elman	1.06	1.27	1.55
	tribas，purelin	Elman	0.58	0.73	1.02
		PSO-Elman	0.32	0.42	0.59
		IPSO-Elman	0.31	0.35	0.44

http://hkxb.buaa.edu.cn

算法的改进很有必要。

当选择训练函数为 trianlm，传递函数为 tansig、purelin 时，3 个模型的预测结果对比如图 6 所示，从图中能够得出 IPSO-Elman 预测精度最高。

PSO-Elman 与 IPSO-Elman 模型的收敛速度对比如图 7 所示，从图中能够看出 IPSO-Elman 的收敛速度明显加快。跳出局部最优的迭代步数与适应度函数的值如表 4 所示。

由表 4 能够得出，基于 IPSO-Elman 的飞机客舱能耗预测模型，其达到适应度函数的稳定值的迭代步数为 96 步，稳定值的适应度函数值为 53.03，相比于 PSO-Elman 预测模型，收敛速度有了一定的提升。可知，该预测模型考虑了学习因子与惯性权重之间的配合调节，同时，引入了变异因子，使得算法在收敛速度与精度上取得了提高。

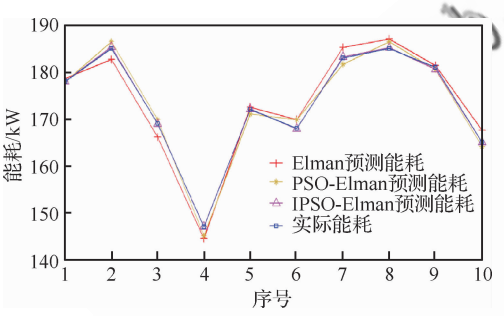


图 6 模型的预测值与真实值对比

Fig. 6 Comparison of predicted and real values of model

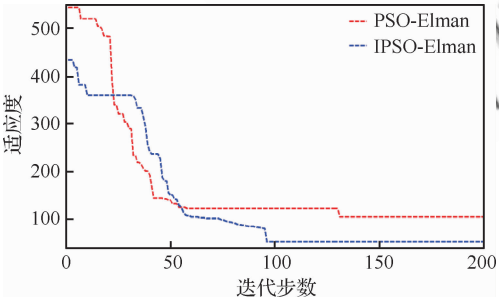


图 7 收敛速度对比

Fig. 7 Comparison of convergence rates

表 4 稳态步数与适应度函数值

Table 4 Steady state steps and fitness function values

方法	迭代步数	适应度
PSO-Elman	132	105.23
IPSO-Elman	96	53.03

5 结 论

1）为准确预测飞机客舱的能耗，通过考虑粒子与全局最优位置的距离并引入变异因子，提出了一种动态调节 PSO 中的学习因子与惯性权重的方法，构造了学习因子与惯性权重的动态调节函数与全局位置的更新函数，进而建立了 IPSO 算法。

2）将 IPSO 与 Elman 算法结合，建立了 IPSO-Elman 的飞机客舱能耗预测模型。

3）通过仿真验证了 IPSO-Elman 相比于 Elman、PSO-Elman 对飞机客舱能耗的预测，在预测精度与收敛速度方面均有一定程度的提高。

IPSO-Elman 飞机客舱能耗预测模型在一定程度上解决了飞机客舱能耗预测的精度不高与收敛速度慢的问题，为飞机地面空调的能耗预测提供了支持。

参 考 文 献

[1] 林家泉，李弯弯. 基于 PMV-PPD 的地面空调最佳送风速度[J]. 航空学报，2017，38(8)：121089.
LIN J Q，LI W W. Best wind speed of ground air conditioning system based on PMV-PPD[J]. Acta Aeronautica et Astronautica Sinica，2017，38(8)：121089 (in Chinese).

[2] CUI W，OUYANG Q，ZHU Y. Field study of thermal environment spatial distribution and passenger local thermal comfort in aircraft cabin[J]. Building & Environment，2014，80(10)：213-220.

[3] 樊兆峰，马小平，邵晓根，等. 非线性系统 RBF 神经网络多步预测控制[J]. 控制与决策，2014，29(7)：1274-1278.
FAN Z F，MA X P，SHAO X G，et al. RBF neural network multi-step predictive control for nonlinear systems [J]. Control and Decision，2014，29(7)：1274-1278 (in Chinese).

[4] 皮骏，马圣，贺嘉诚，等. 基于 IGA-ELM 网络的滚动轴承故障诊断[J]. 航空学报，2018，39(9)：422025.
PI J，MA S，HE J C，et al. Rolling bearing fault diagnosis based on IGA-ELM network[J]. Acta Aeronautica et Astronautica Sinica，2018，39(9)：422025 (in Chinese).

[5] HAMID M F A，RICHARD H G A，RAMLI N A. An analysis on energy consumption of two different commercial buildings in Malaysia[C]// IEEE International Conference on Power & Energy. Piscataway：IEEE Press，2017：344-349.

[6] 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)：263-270.
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)：263-270 (in Chinese).

[7] ZHOU C，DING L Y，HE R. PSO-based Elman neural network model for predictive control of air chamber pressure in slurry shield tunneling under Yangtze River[J]. Automation in Construction，2013，36(15)：208-217.

[8] RATNAWEERA A，HALGAMUGE S K，WATSON H C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients [J]. IEEE Transactions on Evolutionary Computation，2004，8(3)：225-240.

[9] WANG C F，LIU K. An improved particle swarm optimization algorithm based on comparative judgment[J]. Natural Computing，2017，32(6)：123-132.

[10] ARUMUGAM M S，RAO M V C. On the improved performances of the particle swarm optimization algorithms with adaptive parameters，cross-over operators and root mean square (RMS) variants for computing optimal control of a class of hybrid systems[J]. Applied Soft Computing Journal，2008，8(1)：324-336.

[11] LI J W，CHENG Y M，CHEN K Z. Chaotic particle swarm optimization algorithm based on adaptive inertia weight[C]// Proceedings of the 26th China Control and Decision-Making Conference，2014：1310-1315.

[12] ZHANG Y，ZHAO Y，FU X，et al. A feature extraction method of the particle swarm optimization algorithm based on adaptive inertia weight and chaos optimization for Brillouin scattering spectra [J]. Optics Communications，2016，4(37)：56-66.

[13] 王东风，孟丽. 粒子群优化算法的性能分析和参数选择[J]. 自动化学报，2016，42(10)：1552-1561.
WANG D F，MENG L. Performance analysis and parameter selection of PSO algorithms[J]. Acta Automatica Sinica，2016，42(10)：1552-1561 (in Chinese).

[14] ALKHASAWNEH M S，TAY L T. A hybrid intelligent system integrating the cascade forward neural network with elman neural network[J]. Arabian Journal for Science & Engineering，2017，43(12)：6737-6749.

[15] WANG D，TAN D，LIU L. Particle swarm optimization algorithm：An overview[J]. Soft Computing，2017，22(2)：387-408.

[16] ZHANG S，JIANG H H，YIN Y Y，et al. The prediction of the gas utilization ratio based on TS fuzzy neural network and particle swarm optimization[J]. Sensors，2018，18(2)：625-644.

[17] BONYADI M R，MICHALEWICZ Z. Particle swarm optimization for single objective continuous space problems：A review[J]. Evolutionary Computation，2017，25(1)：1-54

[18] SHI Y，EBERHART R C. Empirical study of particle swarm optimization[C]// Congress on Evolutionary Computation，2002：1945-1950.

[19] ZHANG Y，ZHAO Y，FU X，et al. A feature extraction method of the particle swarm optimization algorithm based on adaptive inertia weight and chaos optimization for Brillouin scattering spectra [J]. Optics Communications，2016，4(37)：56-66.

[20] ALAHMER A，OMAR M A，MAYYAS A，et al. Effect of relative humidity and temperature control on in-cabin thermal comfort state：Thermodynamic and psychometric analyses[J]. Applied Thermal Engineering，2015，31(14)：2636-2644.

[21] LONG Q，GUO S，LI Q，et al. Research of converter transformer fault diagnosis based on improved PSO-BP algorithm[J]. IOP Conference Series：Materials Science and Engineering，2017，231(9)：121-127.

[22] GONZALO E，FERNANDEZLUNA J，MARTINEZ J A. A brief historical review of particle swarm optimization [J]. Journal of Bioinformatics & Intelligent Control，2012，1(1)：3-16.

[23] 孟蓉歌，张春化，梁继超. 改进粒子群优化-Elman算法在发动机曲轴脉宽预测中的应用[J]. 中国机械工程，2018，29(7)：766-770.
MENG R G，ZHANG C H，LIANG J C. Applications of advanced PSO-elman in engine crankshaft pulse width predictions[J]. China Mechanical Engineering，2018，29(7)：766-770 (in Chinese).

[24] ALKHASAWNEH M S，TAY L T. A hybrid intelligent system integrating the cascade forward neural network with elman neural network[J]. Arabian Journal for Science & Engineering，2017，3(4)：1-13.

（责任编辑：李明敏）

http://hkxb.buaa.edu.cn
http://hkxb.buaa.alu.cn

Prediction of aircraft cabin energy consumption based on IPSO-Elman neural network

LIN Jiaquan[1,*], SUN Fengshan[1], LI Yachong[1], ZHUANG Zibo[2]

1. *Institute of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China*
2. *Flight Technical College, Civil Aviation University of China, Tianjin 300300, China*

Abstract: To improve the prediction accuracy of cabin energy consumption when the aircraft cabin uses ground air conditioning for refrigeration, an aircraft cabin energy consumption prediction model based on the Improved Particle Swarm Optimization (IPSO) Elman neural network is proposed. The main procedure of the IPSO is as follows: the convergence domain analysis of the inertia weight and the learning factors is used to obtain a reasonable range of these two parameters; the range of the two parameters and the distance from the particle to the global optimal position are combined to dynamically adjust the two parameters; the dynamic adjustment function of the inertia weight and the learning factors are then constructed; a variation factor is introduced and a strategy proposed to prevent the PSO from being trapped in the local optimum. The IPSO-Elman is applied to the Boeing738 aircraft cabin energy consumption prediction and compared with PSO-Elman and Elman. The simulation results show the effectiveness of the cabin energy consumption prediction model based on IPSO-Elman in improving both the prediction accuracy and the convergence rate. The research results establish a theoretical basis for the aircraft cabin energy prediction model and provide further support for the energy saving of ground air conditioning and the reasonable allocation of airport electrical energy.

Keywords: aircraft cabin; ground air condition; energy demands prediction; particle swarm optimization; Elman neural network

http://hkxb.buaa.edu.cn

Received: 2019-10-30; **Revised**: 2019-11-19; **Accepted**: 2020-02-01; **Published online**: 2020-02-07 09:28
URL: http://hkxb.buaa.edu.cn/CN/html/20200719.html
Foundation item: Joint Fund of the National Natural Science Foundation of China and the Civil Aviation Administration of China (U1433202)
* **Corresponding author.** E-mail: jqlin@cauc.edu.cn