

1-8-2019

Prediction of Aircraft Cabin Energy Consumption Based on PSO and CRO Algorithms

Xiuyan Wang

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

Yanmin Liu

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

Gewen Zhang

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

Zongshuai Li

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

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Prediction of Aircraft Cabin Energy Consumption Based on PSO and CRO Algorithms

Abstract

Abstract: To meet the requirements of the rapidity and the accuracy of the aircraft cabin energy consumption prediction for bridge-load air conditioner when an aircraft berthing, a forecasting method based on the combination of neural network, particle swarm and coral reef is proposed. The energy consumption prediction model is established based on wavelet neural network, and the prediction model parameters are optimized using the united algorithm of coral reefs and particle swarm optimization. *The united algorithm adopts a double-layer structure: the data of the first layer are grouped and optimized by the particle swarm optimization algorithm for a preliminary optimization, and the first layer optimization results are put into the second layer; the second layer makes use of coral reef algorithm for further optimization, so as to improve the prediction accuracy and solve the problem of slow convergence rate and easy to fall into local extremum.* The simulation results show that the proposed united algorithm can effectively improve the prediction speed and accuracy of energy consumption.

Keywords

united algorithm, wavelet neural network, particle swarm optimization, coral reef optimization, aircraft cabin, energy consumption prediction

Authors

Xiuyan Wang, Yanmin Liu, Gewen Zhang, Zongshuai Li, and Jiaquan Lin

Recommended Citation

Wang Xiuyan, Liu Yanmin, Zhang Gewen, Li Zongshuai, Lin Jiaquan. Prediction of Aircraft Cabin Energy Consumption Based on PSO and CRO Algorithms[J]. Journal of System Simulation, 2018, 30(8): 3074-3081.

基于 PSO 和 CRO 联合算法的飞机客舱能耗预测

王修岩, 刘艳敏, 张革文, 李宗帅, 林家泉

(中国民航大学 电子信息与自动化学院, 天津 300300)

摘要: 为了满足飞机停靠时基于地面空调的客舱能耗预测的快速性和准确性要求, 提出了一种神经网络、微粒群和珊瑚礁相结合的飞机客舱能耗预测方法, 该方法是基于小波神经网络建立能耗预测模型, 采用珊瑚礁和微粒群联合算法优化预测模型参数。联合算法采用了双层框架, 第一层将数据进行分组采用微粒群算法进行初步优化, 之后将第一层优化结果送入第二层, 在第二层利用珊瑚礁算法进一步优化, 以提高预测精度并解决微粒群算法收敛速度慢、容易陷入局部极值的问题。最后进行了仿真, 结果表明提出的联合算法能有效提高能耗预测速度和能耗预测的精度。

关键词: 联合算法; 小波神经网络; 微粒群算法; 珊瑚礁算法; 飞机客舱; 能耗预测

中图分类号: TH137.8

文献标识码: A

文章编号: 1004-731X (2018) 08-3074-08

DOI: 10.16182/j.issn1004731x.joss.201808031

Prediction of Aircraft Cabin Energy Consumption Based on PSO and CRO Algorithms

Wang Xiuyan, Liu Yanmin, Zhang Gewen, Li Zongshuai, Lin Jiaquan

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

Abstract: To meet the requirements of the rapidity and the accuracy of the aircraft cabin energy consumption prediction for bridge-load air conditioner when an aircraft berthing, a forecasting method based on the combination of neural network, particle swarm and coral reef is proposed. The energy consumption prediction model is established based on wavelet neural network, and the prediction model parameters are optimized using the united algorithm of coral reefs and particle swarm optimization. *The united algorithm adopts a double-layer structure: the data of the first layer are grouped and optimized by the particle swarm optimization algorithm for a preliminary optimization, and the first layer optimization results are put into the second layer; the second layer makes use of coral reef algorithm for further optimization, so as to improve the prediction accuracy and solve the problem of slow convergence rate and easy to fall into local extremum.* The simulation results show that the proposed united algorithm can effectively improve the prediction speed and accuracy of energy consumption.

Keywords: united algorithm; wavelet neural network; particle swarm optimization; coral reef optimization; aircraft cabin; energy consumption prediction

引言

基于飞机运行成本与安全、空气质量、噪音控



收稿日期: 2016-11-18 修回日期: 2017-01-13;
基金项目: 国家自然科学基金-中国民航局民航联合
研究基金(U1433107);

作者简介: 王修岩(1965-), 男, 吉林农安, 博士, 教
授, 研究方向为非线性系统建模与控制研究; 刘艳敏
(1990-), 女, 山东临沂, 硕士生, 研究方向为飞机客
舱能耗预测。

制以及机坪拥堵的角度, 在航前、航后及过站阶段使用地面专用设备替代飞机 APU 提供飞机地面作业的电力和空调供应有很多的好处^[1]。当前, 地面专用空调设备使用和控制存在一定的盲目性和能源浪费问题, 所以有对地面飞机客舱能耗需求进行评估和预测进行研究的必要。

飞机地面空调与飞机客舱的整体是一个复杂

<http://www.china-simulation.com>

• 3074 •

的热力学系统,同时还受到空调外部送风管道以及飞机客舱内部复杂通风管道的影响,具有较大的滞后性和非线性,很难推导出系统精确的数学模型。小波神经网络(wavelet neural network, WNN)预测方法对大量非结构性、非精确性规律的系统具有自适应的功能^[2],但其预测的精度不能满足要求,而且其网络收敛速度较慢。所以基于小波神经网络的预测必须解决小波神经网络权值的准确估计及快速收敛问题。为了解决这个问题,需要设计一种优化算法来对神经网络的权值系数进行优化^[3]。预测模型是为后续地面专用空调设备使用和控制提供技术支持,所以需要达到控制要求的预测准确性。优化算法的目标是寻找到神经网络权值的适合值,在保证神经网络的泛化能力不降低的同时使得预测误差减小到十分之一以下。文献[4]提出了一种基于多种群分层的粒子群算法,在每个小种群中采用微粒群算法(particle swarm optimization, PSO)优化,然后将每个小种群的最优粒重新组成一个新的粒子群,在新的粒子群中用微粒群算法再次进行优化,通过两次微粒群算法优化提高了算法的搜索能力。微粒群算法在求解局部最优值表现较好,但是全局搜索能力仍有待提高^[5-9]。文献[10]提出了珊瑚礁算法(coral reefs optimization, CRO),该算法模拟珊瑚虫群行为和珊瑚礁筑成的智能优化算法,具有寻优速度快,误差小的特点,但是珊瑚虫选择的随机性造成 CRO 算法在局部进行精细搜索的能力较差。

结合以上分析,本文提出了一种将微粒群算法和珊瑚礁算法相结合优化小波神经网络权值系数的算法。该算法采用双层框架,在第一层将数据分成多个组,在每个组采用微粒群算法优化;将优化结果送到第二层作为珊瑚礁算法的初始粒子,利用珊瑚礁算法进一步优化,最后再将结果返回第一层。该方法有效地解决了微粒算法在优化过程中出现的收敛速度较慢和容易陷入局部极值的问题,也克服了珊瑚礁算法在局部搜索不够精细的问题。

1 飞机客舱能耗预测模型

飞机客舱本身是一个复杂的系统,能耗的预测也因外部环境和内部环境的实时变化而变得比较困难。实际中飞机客舱的能耗、负荷与各影响因素之间关系存在复杂的非线性关系,使得模型的建立非常困难^[11]。小波神经网络在逼近能力和学习速度上具有较强的优势,在样本数据较少时,预测效果也较好。因此本文通过小波神经网络预测方法建立系统的能耗预测模型,为飞机地面空调的优化控制研究提供参考。

1.1 小波神经网络

小波神经网络是以 BP 神经网络拓扑结构为基础,把小波基函数作为隐含层节点的传递函数,信号前向传播的同时误差反向传播的神经网络^[12]。对应的网络输入 X_1, X_2, \dots, X_k , 其输出为 Y_1, Y_2, \dots, Y_m 。在输入信号序列为 $X_i (i=1, 2, \dots, k)$ 时, 隐含层输出计算公式为:

$$h(j) = h_j \left[\frac{\sum_{i=1}^k \omega_{ij} x_i - b_j}{a_j} \right], j = 1, 2, \dots, l \quad (1)$$

式中: $h(j)$ 为隐含层第 j 个节点输出值; ω_{ij} 为输入层和隐含层的连接权值; h_j 为小波基函数; b_j 为小波基函数的平移因子; a_j 为小波基函数的伸缩因子。

小波神经网络输出层计算公式为:

$$y(k) = \sum_{i=1}^l \omega_{ik} h(i), k = 1, 2, \dots, m \quad (2)$$

式中: $h(i)$ 为第 i 个隐含层节点输出; ω_{ik} 为隐含层到输出层的权值; l 为隐含层节点数; m 为输出层节点数。

1.2 小波神经网络建立客舱能耗模型

本文以波音 737 飞机为例子,单独考虑外部空调制冷对飞机客舱的影响,建模的主要目的是建立客舱内冷热耗量的主要影响因素与外部空调供能之间的能耗关系。空调系统能耗受多个参数影响:

客舱内空气流动形成的速度场、温度场、气流组织、机务人员和乘客的长波辐射；客舱外的温湿度、太阳辐射、风速、环境长波辐射等，都是影响客舱能耗的因素。从空调机组方面分析：室外空气湿度温度影响冷却塔的效率，同时影响冷水机组冷凝压力，进而影响到机组 COP；室内外温差、太阳辐射强度、乘客密度影响冷冻水水量，进而影响水泵能量输送效率，虽然有这些因素影响，但是空调系统能量输送效率变化很小。因此客舱内外自然环境以及人员因素对空调系统的能耗影响几乎可以忽略不计。影响客舱内冷热环境的因素主要是温度和湿度，这两个因素不是完全独立的变量，而是相互作用的^[13]。因此将飞机下客完毕时机舱口的温度、湿度和达到舒适度要求时机舱口的温度、湿度这四个因素作为神经网络的输入，由下客完毕时开始到达舒适度要求时为止，在这个过程中飞机地面空调的耗电量作为神经网络的输出，由此构建小波神经网络的预测模型。

小波神经网络的预测需要解决小波神经网络权值的准确估计的问题已达到系统高精度预测和快速收敛的目的，所以本文设计了一种联合优化算法，用来优化神经网络的权值参数，优化结构图如图1所示。




图1 参数优化结构图

Fig. 1 Parameter optimization structure diagram

2 联合算法优化小波神经网络参数

飞机客舱的能耗预测是为地面专用空调设备

使用和控制提供技术支持，所以需要达到控制要求的预测准确性。根据 Moody 准则，神经网络的设计最简原则是：对于达到给定训练精度的神经网络，其有效参数越少，泛化能力越好。所以神经网络参数的选取，不仅会影响到训练精度的大小，还会影响到泛化能力的大小。本文选取 PSO 和 CRO 联合的优化算法，目的是在保证神经网络泛化效果较好的情况之下实现飞机客舱能耗预测的准确性要求。

2.1 微粒群优化算法

微粒群优化算法是通过互相学习和模仿，寻找全局的最优点的过程。整个算法由多个微粒组成，每个微粒代表了优化问题的潜在可行解^[14]。本文所用的微粒群优化算法是带有模糊聚类的微粒群优化算法，为了加快整个算法的寻优过程，该算法采用模糊 C 均值算法解决分组问题。

2.1.1 基本微粒群算法

微粒的速度和位置更新公式为：

$$v_{id}(t+1) = wv_{id}(t) + c_1r(\bullet)[y_{id}(t) - x_{id}(t)] + c_2r(\bullet)[y_{gd}(t) - x_{id}(t)] \quad (3)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (4)$$

式中： $i=1,2,\dots,g$ ； $d=1,2,\dots,n$ ； w 是惯性权重， $w \in [0,1]$ ； c_1, c_2 是加速系数且为非负常数； $r(\bullet) \in [0,1]$ 的随机序列； v_{id} 是第 i 个微粒在第 d 维空间上的速度； x_i 是第 i 个微粒在空间中的位置； y_i 是每个微粒经过的最好位置。

2.1.2 模糊 C 均值聚类算法

聚类是多变量数据分析的一种基本方法，其目标是将相似的数据分在同一个类别内，不相似的数据分在不同的类别内^[15]。模糊 C 均值聚类是一种典型的聚类方法，利用该方法对种群进行划分，将整个种群换分成 M 个组。

它主要优化的如下的目标函数：

$$J_m(U, V) = \sum_{k=1}^N \sum_{i=1}^C u_{ik}^m (x_k - v_k)^T (x_k - v_k) \quad (5)$$

式中: u_{ik}^m 是数据点 x^k 属于聚类中心 v_i 的隶属度, $(x_k - v_k)^T(x_k - v_k)$ 代表着两者之间的欧式距离, m 是模糊指数。模糊 C 均值属于带有约束条件的优化问题, 约束条件为:

$$\begin{aligned} \sum_{k=1}^N u_{ik} > 0, \sum_{i=1}^C u_{ik} = 1, 0 \leq u_{ik} \leq 1, \\ i = 1, 2, \dots, C; k = 1, 2, \dots, N \end{aligned} \quad (6)$$

隶属度和聚类中心可以通过如下迭代式目标函数最小:

$$u_{ik} = \frac{1}{\sum_{i=1}^C \left[\frac{(x_k - v_i)^T(x_k - v_i)}{(x_k - v_i)(x_k - v_i)^T} \right]^{\frac{1}{m-1}}} \quad (7)$$

$$i = 1, 2, \dots, C; k = 1, 2, \dots, N$$

$$v_i = \frac{\sum_{k=1}^N (u_{ik})^m x_k}{\sum_{k=1}^N (u_{ik})^m}; i = 1, 2, \dots, C \quad (8)$$

通过迭代式(7)和式(8)可以获得目标函数较好地解。

2.2 珊瑚礁优化算法

珊瑚礁算法是由 Sancho 等根据珊瑚虫群行为和珊瑚礁筑成过程提出的优化算法, 珊瑚虫群的行为分成繁殖、竞争、淘汰等环节^[16]。

繁殖过程: 设在大小为 $X \times Y$ 的珊瑚礁上面有 $X \times Y$ 个珊瑚虫附着的节点, 其中有比例为 ρ 的珊瑚附着在珊瑚礁上, 即珊瑚虫的附着数量为: $X \times Y \times \rho$; 设 ζ 为珊瑚虫雌雄异体的比例, 则 $X \times Y \times \rho \times \zeta$ 作为亲代 Q_1 和 Q_2 , 并通过模拟二进制交叉的方式结合, 产生 2 个子代 q_1 和 q_2 :

$$\begin{cases} q_{1,\alpha} = [(1+\phi)Q_{1,\alpha} + (1-\phi)Q_{2,\alpha}] / 2 \\ q_{2,\alpha} = [(1-\phi)Q_{1,\alpha} + (1+\phi)Q_{2,\alpha}] / 2 \end{cases} \quad (9)$$

$$\alpha = 1, 2, \dots, \psi$$

式中: α 为迭代次数; ψ 为最大迭代次数; ϕ 是由式(10)产生的随机变量:

$$\phi = \begin{cases} (2\tau)^{\frac{1}{k+1}}, \tau < 0.5 \\ [2(1-\tau)]^{\frac{1}{k+1}}, \tau > 0.5 \end{cases} \quad (10)$$

τ 为随机数, 且 $\tau \in (0, 1)$; k 为二进制交叉常数。

剩余雌雄同体的珊瑚虫数量为 $X \times Y \times \rho \times (1 - \zeta)$ 的亲代为 Q , 其产生的子代为 q :

$$q_\alpha = Q_\alpha + \text{rand}(-1, 1) \times (Q_\alpha^{\max} - Q_\alpha^{\min}) \quad (11)$$

竞争过程: 此时有数量为 $X \times Y \times (1 - \rho)$ 的珊瑚礁没有被附着, 子代的珊瑚虫会随机寻找珊瑚礁进行附着, 如果该珊瑚礁还没有被别的珊瑚虫附着, 则子代珊瑚虫就能够成功附着在上面; 如果该珊瑚礁已经被其他的珊瑚虫附着了, 则比较各自的健康度值(适应度函数值 $f(p)$), 健康度值优的珊瑚虫会抢占该珊瑚礁。没有能够附着成功的珊瑚虫按上述过程继续寻找, 设子代珊瑚虫附着的极限次数为 μ , 如果在该极限次数以内子代珊瑚虫没有附着成功, 则该珊瑚虫会死亡。

淘汰过程: 设珊瑚虫的繁殖分裂比例为 λ , 即有比例为 λ 的珊瑚虫会分裂产生子代, 并按竞争的过程尝试附着。设每次循环中珊瑚虫被淘汰的概率为 ε , 淘汰的珊瑚虫数量比例为 δ 。珊瑚虫一旦被淘汰就会自动死亡, 它们所附着的珊瑚礁就会空出来供其他的珊瑚虫进行竞争。

重复上述的三个过程, 达到最大的迭代次数 ψ 时, 附着在珊瑚礁上且健康度最优的珊瑚虫 q 就是最优解。

2.3 联合算法优化模型参数

2.3.1 双层优化结构

PSO 算法的局部搜索能力比较强, 但是其容易陷入局部最优的情况, 在收敛速度和寻优精度方面效果也需要进一步改进。CRO 算法由于其本身的随机性所以比较容易跳出局部最优解, 具有一定的全局搜索能力。本文提出了联合优化算法, 将 PSO 算法和 CRO 算法相结合建立双层优化框架。首先, 利用模糊 C 均值聚类算法将种群进行分组, 第一层由 PSO 算法对每个小种群分别进行初步优化, scb_i 是第 i 个小种群的最优解; 然后, 将各个小种群中得到的最优粒子送到第二层, 由 CRO 算法的再一次进行精确优化, 这一层得到的最优解 C_{best}

再返回到第一层的小种群中^[17]。这种双层的联合优化算法能够加快寻优的收敛速度,同时提高寻优精度。联合优化算法双层优化框架如图2所示。

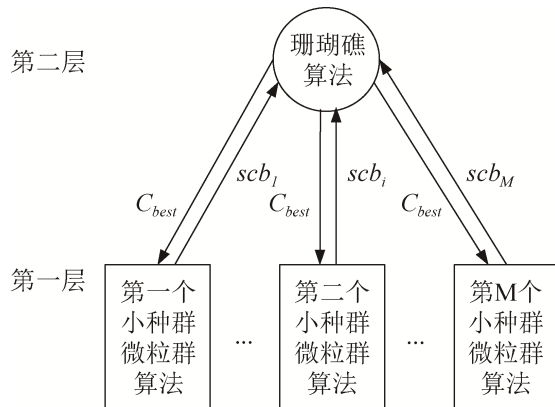


图2 联合算法的双层框架

Fig. 2 Dual layer framework of united algorithm

2.3.2 联合算法步骤

第一层算法:

Step 1: 初始化粒子群. 设置粒子群总数 S 、小种群个数 M 等常量。

Step 2: 设定聚类数目 C , 模糊指数 m , 最大循环次数 $Loop$, 收敛系数 ε 。

Step 3: 随机初始化聚类中心, 利用迭代式(7)和式(8)计算并更新模糊隶属度和聚类中心, 对优化问题维数 D 进行聚类分为 M 组, 如果维数 $n_i < (3D/10M)$, 引入抑制机制重新分组。

Step 4: 在每组种群中, 计算单个粒子的适应度作为它的历史最优值, 根据式(3)和式(4)更新每组小种群中各个粒子的速度和位置, 并计算每个粒子的适应度。

Step 5: 比较每个粒子的当前适应度值和历史最优值, 用二者中最优的值更新历史最优值。分别计算各组种群的最优值, 并将结果送给第二层; 同时比较整个种群的当前最优值和历史最优值, 用二者中最优的值更新整个种群的历史最优值。

第二层算法:

Step 6: 将第一层 M 个小种群的最优解送到第二层作为珊瑚虫的初始位置, 初始化珊瑚虫所在珊

瑚礁的位置, 对算法的相关参数的初始化, 设置最大迭代次数为 Ψ 。

Step 7: 根据公式(9), 公式(10)和公式(11)更新珊瑚虫的子代。

Step 8: 子代珊瑚虫按照竞争过程和淘汰过程进行寻优。

Step 9: 找出最后得到的最优解, 如果得到的最优解大于在第一层中求得的历史最优解, 则用珊瑚礁优化的最优解作为历史最优解。

Step 10: 判断算法是否达到最大的迭代次数, 如果没有, 则返回继续寻优。

2.3.3 联合算法收敛性分析

首先给出如下定义: 求解的问题 P 的定义域是 R^n 的有界闭区间且适应值函数 $f(x)$ 是区间上的连续函数。

定理 1: 设 Z_t 为 t 时刻种群中所包含的个体适应值的最大值, f^* 是适应值函数 $f(x)$ 在所有可能的个体所组成的集合 X 中取得的最大值, 若 Z_t 满足:

$$\lim_{t \rightarrow \infty} P(Z_t = f^*) = 1 \quad (12)$$

则称算法收敛到最优解。

联合算法每个粒子的速度更新公式如下:

$$v_{id}(t+1) = wv_{id}(t) + c_1r(\bullet)[scg_i - x_{id}(t)] + c_2r(\bullet)[C_{best} - x_{id}(t)] \quad (13)$$

式中: scg_i 是每个小种群的聚类中心; C_{best} 是种群的最优解。

$$\phi_1(t) = c_1r(\bullet)[scg_i - x_{id}(t)];$$

$$\phi_2(t) = c_2r(\bullet)[C_{best} - x_{id}(t)]$$

则速度的更新公式化成时变离散差分方程为:

$$v_{t+2} + [\phi_1(t) + \phi_2(t) - w - 1]v_{t+1} + wv_t = 0 \quad (14)$$

$$\text{设 } \Phi_{t+1} = \phi_1(t) + \phi_2(t) - w - 1;$$

则差分方程可化为:

$$v_{t+2} + \Phi_{t+1}v_{t+1} + wv_t = 0 \quad (15)$$

式(14)化成矩阵形式为:

$$\begin{cases} v_{t+1} = -\Phi_t v_t + y_t \\ y_{t+1} = -wv_t \end{cases} \quad (16)$$

参考文献[18]中构造李亚普诺夫函数, 可以证

明定理 1 成立, 同时能够得到一般粒子的稳定条件容易满足。

3 仿真实验结果与分析

为了验证联合优化算法优化的神经网络预测方法是否能够达到提高预测精度的要求, 本文在 MATLAB2014a 环境下进行了仿真实验。

根据某机场 8 月份停靠的波音 737 飞机为例, C 类机位采用制冷量 150 kW 的单元式空调, 其配置的最大电功率为 95 kW, 采集了样本数据如表 1 所示。

表 1 样本数据
Tab. 1 Sample data

日期	起始温度/°C	起始湿度/%	最终温度/°C	最终湿度/%	耗电量/kW
8.6	31.60	47.53	24.31	24.08	178
8.7	33.30	67.07	24.77	34.52	185
8.8	32.52	72.52	23.98	35.52	169
8.9	29.38	61.18	26.26	34.87	147
8.10	32.63	57.08	25.32	28.67	172
8.11	30.10	62.85	24.50	32.56	168
8.12	32.50	51.18	23.00	35.81	183
8.13	29.00	72.85	25.00	37.28	155
8.14	31.50	55.68	24.60	36.31	181
8.15	29.67	62.52	23.65	35.78	165

为了验证神经网络预测方法的抗噪能力, 本文在表 1 的基础上, 对每组样本数据按式(17)叠加 $K=0.1$ 的噪声信号, 每组样本数据产生 50 个测试样本, 总共得到 500 个测试样本。对于前 400 个样本作为训练集, 后 100 个样本作为测试集。

$$x_i = x_i + K\delta_f \times \text{randn}(1,50) \quad (17)$$

式中: K 表示噪声幅值水平; δ_f 为已知样本数据中各偏差的标准差; 函数 randn 产生一个服从标准正态分布的随机数。

3.1 预测精度比较分析

由图 3 可知, 虚线部分是微粒群算法优化的神经网络预测的误差绝对值, 实线部分是联合算法优化的神经网络的误差绝对值。当单独采用微粒群优

化方法来优化小波神经网络的参数时, 预测的误差绝对值在 0.15 左右, 预测的误差较大; 当采用联合优化方法来优化小波神经网络的参数时, 预测误差降低到了 0.05 左右, 明显可以看出联合优化方法使系统的预测精度得到了较好的提高。




图 3 预测误差绝对值比较

Fig. 3 Comparison of absolute value of prediction error

为了验证飞机客舱预测模型的准确性, 将用来做测试集的 100 个样本输入网络进行测试, 结果如图 4 所示, 从预测输出结果可以看出改进的协同微粒群优化的神经网络预测模型能够比较精确的预测飞机客舱的耗电量情况。




图 4 飞机客舱能耗预测输出

Fig. 4 Aircraft cabin energy consumption forecast output

3.2 预测模型收敛性比较分析

为了验证改进方法的收敛效果, 将微粒群优化广义回归神经网络(GRNN)、小波神经网络、PSO

优化小波神经网络和联合算法优化的小波神经网络进行比较仿真,采用一致的网络初始条件进行训练。机器学习性能可以通过泛化误差表达,泛化误差越小,则该方法的学习性能越好,反之则学习性能越差。在大多数工程问题中泛化误差的应该保持在[0,1]区间范围内,误差值越小,代表泛化能力越好,反之则泛化能力越差。由图5可以看出,联合算法优化神经网络的预测方法能够在系统预测精度提高一个数量级的基础上,在较少的循环次数内快速收敛。因此,联合算法优化神经网络的预测方法在收敛速度和预测精度两方面得到较好地提高。

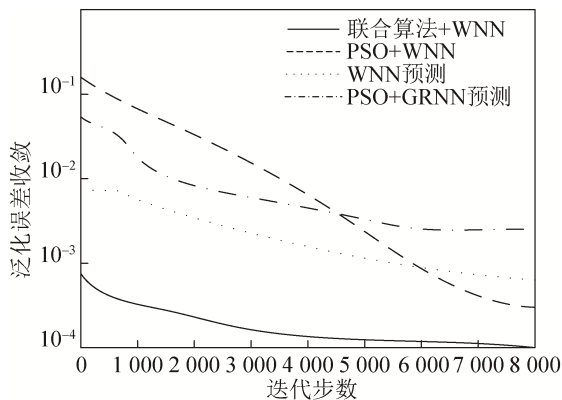


图5 泛化误差收敛曲线的比较

Fig. 5 Comparison of convergence curves of generalization error

4 结论

本文针对小波神经网络在飞机客舱能耗预测方面存在的预测精度和收敛速度的问题,提出联合算法优化神经网络参数的预测方法。该方法将微粒群优化算法和珊瑚礁优化算法相结合建立联合优化算法。综合微粒群算法和珊瑚礁算法的优点,建立双层联合寻优框架,并且通过模糊C均值聚类算法对第一层粒子群进行分组;同时利用珊瑚礁算法在优化过程中的收敛速度较快的优点,在第二层进行二次优化,提高预测模型的收敛速度。通过仿真验证了,采用联合算法优化的神经网络建立的飞机客舱能耗预测模型的预测精度较高,收敛速度较快,较准确的评估了飞机客舱在供冷情况下的能耗需求,为地面专用设备的推广使用提供了一

定的支持。

参考文献:

- [1] 费春国, 王鹏鹏. 桥载设备计量监测与管理系统的电量自动采集[J]. 自动化与仪表, 2014, 29(9): 53-56, 65.
Fei C G, Wang P P. Axle load measuring equipment monitoring and management system for power automatic acquisition [J]. Automation & Instrumentation, 2014, 29(9): 53-56, 65.
- [2] K S Kasiviswanathan, Jianxun He, K P Sudheer, et al. Potential application of wavelet neural network ensemble to forecast streamflow for flood management[J]. Journal of Hydrology (S0022-1694), 2016, 23(4): 71-76.
- [3] 程声烽, 程小华, 杨露. 基于改进粒子群算法的小波神经网络在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2014(19): 37-42.
Cheng S S, Cheng X H, Yang L. Application of wavelet neural network with improved particle swarm optimization algorithm in power transformer fault diagnosis [J]. Power System Protection and Control, 2014(19): 37-42.
- [4] 吕林, 罗绮, 刘俊勇, 等. 一种基于多种群分层的粒子群优化算法[J]. 四川大学学报(工程科学版), 2008, 40(5): 171-176.
Lu L, Luo Q, Liu J Y, et al. A hierarchical structure poly-particle swarm optimization algorithm[J]. J of Sichuan University(Engineering Science Edition), 2008, 40(5):171-176.
- [5] 刘建华, 刘国买, 杨荣华, 等. 粒子群算法的交互性与随机性分析[J]. 自动化学报, 2012, 38(9): 1471-1484.
Liu J H, Liu G M, Yang R H, et al. Analysis of Interactivity and Randomness in Particle Swarm Optimization [J]. Acta Automatica Sinica, 2012, 38(9): 1471-1484.
- [6] 陈如清, 俞金寿. 混沌粒子群混合优化算法的研究与应用[J]. 系统仿真学报, 2008, 20(3): 685-688.
Chen R Q, Yu J S. Research and application of chaos particle swarm hybrid optimization algorithm [J]. Journal of System Simulation, 2008, 20(3): 685-688.
- [7] 王皓, 欧阳海滨, 高立群. 一种改进的全局粒子群优化算法[J]. 控制与决策, 2016, 31(7): 1161-1168.
Wang H, Ouyang H B, Gao L Q. QAn improved global particle swarm optimization [J]. Control and Decision, 2016, 31(7): 1161-1168.
- [8] 李光宇, 郭晨, 李延新. 基于改进粒子群算法的 USV 航向分数阶控制[J]. 系统工程与电子技术, 2014, 21(6): 1146-1151.

- Li G Y, Guo C, Li Y X. Fractional-order control of USV course based on improved PSO algorithm[J]. *Systems Engineering and Electronics*, 2014, 21(6): 1146-1151.
- [9] 韩江洪, 李正荣, 魏振春. 一种自适应粒子群优化算法及其仿真研究[J]. *系统仿真学报*, 2006, 18(10): 2969-2971.
- Han J H, Li Z R, Wei Z C. An adaptive particle swarm optimization algorithm and its simulation research [J]. *Journal of System Simulation*, 2006, 18(10): 2969-2971.
- [10] Salcedo-Sanz S, Del Ser J, Gil-López S, et al. The Coral Reefs Optimization Algorithm: An Efficient Meta-heuristic for Solving Hard Optimization Problems [C]// Proc. of the 15th International Conference on Applied Stochastic Models and Data Analysis (ASMDA), Mataró, Barcelona, Spain, 2013: 751-758.
- [11] 孙贺江, 安璐, 冯壮波, 等. 客机驾驶舱流场 CFD 模拟与热舒适性分析[J]. *天津大学学报(自然科学与工程技术版)*, 2014, 13(4): 298-303.
- Sun H J, An L, Feng Z B, et al. CFD Simulation and Thermal Comfort Analysis in an Airliner Cockpit [J]. *Journal of Tianjin University(Science and Technology)*, 2014, 13(4): 298-303.
- [12] Zhang Jian, Yang Xiaohua, Chen Xiaojuan, et al. Wavelet Network Model Based on Multiple Criteria Decision Making for Forecasting Temperature Time Series[J]. *Mathematical Problems in Engineering (S1024-123X)*, 2015, 12(1): 87-92.
- [13] 刘俊杰, 李炳焯, 裴晶晶, 等. 不同季节飞机客舱环境的主客观实验研究[J]. *天津大学学报(自然科学与工程技术版)*, 2015, 56(2): 103-110.
- Liu J J, Li B Y, Pei J J, et al. Subjective and Objective Experimental Study of Cabin Environment in Different Seasons [J]. *Journal of Tianjin University(Science and Technology)*, 2015, 56(2): 103-110.
- [14] 范剑超, 韩敏. 微粒群优化动态神经网络模型结构分析[J]. *控制理论与应用*, 2011, 28(9): 1075-1081.
- Fan J C, Han M. Model-structure analysis of dynamic neural networks with particle-swarm optimization [J]. *Control Theory & Applications*, 2011, 28(9): 1075-1081.
- [15] 周世波, 徐维祥, 柴田. 基于数据加权策略的模糊 C 均值聚类算法[J]. *系统工程与电子技术*, 2014, 36(11): 2314-2319.
- Zhou S B, Xu W X, Chai T. Data-weighted fuzzy C-means clustering algorithm[J]. *Systems Engineering and Electronics*, 2014, 36(11): 2314-2319.
- [16] Salcedo-Sanz S, Gallo-Marazuela D, Pastor-Sánchez A, et al. Offshore wind farm design with the Coral Reefs Optimization algorithm [J]. *Renewable Energy (S0960-1481)*, 2014, 63(2): 109-115.
- [17] 高云龙, 闫鹏. 基于多种群粒子群算法和布谷鸟搜索的联合寻优算法[J]. *控制与决策*, 2016, 31(4): 601-608.
- Gao Y L, Yan P. Unified optimization based on multi-swarm PSO algorithm and cuckoo search algorithm [J]. *Control and Decision*, 2016, 31(4):601-608.
- [18] 胡成玉, 吴湘宁, 颜雪松. 微粒群算法中粒子运动稳定性分析[J]. *智能系统学报*, 2011, 6(5): 445-449.
- Hu C Y, Wu X N, Yan X S. Stability analysis of the particle dynamics in a particle swarm optimization [J]. *CAAI Transactions on Intelligent Systems*, 2011, 6(5): 445-449.

(上接第 3073 页)

- [14] MIAO Jie, HU Zheng, ZHANG Yifan, et al. Stackelberg game theoretic pricing algorithm for bandwidth allocation in cooperative access[J]. *The Journal of China Universities of Posts and Telecommunications (S1005-8885)*, 2012, 19(4): 34-42.
- [15] Leyffer S, Munson T. Solving multi leader common follower games[J]. *Optimization Methods and Software (S1055-6788)*, 2010, 25(4): 601-623.
- [16] 何健, 丁晓群, 陈光宇, 等. 基于混沌并行差分进化算法的含风电配电网无功优化[J]. *电力建设*, 2014, 35(11): 1-6.
- He Jian, Ding Xiaoqun, Chen Guangyu, et al. Reactive Power Optimization of Distribution Network with Wind Power Based on Chaotic Parallel Differential Evolution Algorithm[J]. *Electric power construction*, 2014, 35(11): 1-6.