

Journal of System Simulation

Volume 30 | Issue 4

Article 40

1-4-2019

Prediction of Aircraft Cabin Energy Consumption Based on Improved Cooperative PSO Neural Network

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 Improved Cooperative PSO Neural Network

Abstract

Abstract: To correctly evaluate the energy needs of the aircraft cabin and to predict the energy consumption of the aircraft cabin with higher accuracy, an energy consumption prediction method based on improved particle swarm optimization (PSO) neural network algorithm parameters is proposed. *The method combines the cooperative particle swarm optimization algorithm with chaotic particle swarm optimization algorithm. On the basis of cooperative particle swarm optimization algorithm chaos theory is introduced. Continuous search ability by using chaos optimization method to overcome the collaborative optimization algorithm is easy to fall into the local extremum problem.* The parameters of the neural network can accelerate the convergence rate of the cabin, and also can improve the accuracy of prediction by improving the particle swarm optimization algorithm. Simulation results verify the validity and feasibility of the proposed method.

Keywords

improved cooperative PSO, neural network, 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 Improved Cooperative PSO Neural Network[J]. Journal of System Simulation, 2018, 30(4): 1535-1541.

基于改进协同 PSO 的神经网络飞机客舱能耗预测

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: 为了正确评估飞机客舱的能耗需求, 针对飞机客舱能耗预测时对精度要求较高的问题, 提出了改进微粒群算法优化神经网络参数的能耗预测方法。该方法将协同微粒群优化算法和混沌映射微粒群优化算法相结合, 在协同微粒群优化算法的基础之上引入混沌思想。利用混沌优化方法的持续搜索能力克服协同优化算法容易陷入局部极值的问题。神经网络的参数通过改进微粒群算法优化以后, 能够加快客舱预测的收敛速度, 提高预测精度。通过仿真验证了该预测方法的有效性和可行性。

关键词: 改进协同 PSO; 神经网络; 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) 04-1535-07

DOI: 10.16182/j.issn1004731x.joss.201804040

Prediction of Aircraft Cabin Energy Consumption Based on Improved Cooperative PSO Neural Network

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 correctly evaluate the energy needs of the aircraft cabin and to predict the energy consumption of the aircraft cabin with higher accuracy, an energy consumption prediction method based on improved particle swarm optimization (PSO) neural network algorithm parameters is proposed. The method combines the cooperative particle swarm optimization algorithm with chaotic particle swarm optimization algorithm. On the basis of cooperative particle swarm optimization algorithm chaos theory is introduced. Continuous search ability by using chaos optimization method to overcome the collaborative optimization algorithm is easy to fall into the local extremum problem. The parameters of the neural network can accelerate the convergence rate of the cabin, and also can improve the accuracy of prediction by improving the particle swarm optimization algorithm. Simulation results verify the validity and feasibility of the proposed method.

Keywords: improved cooperative PSO; neural network; aircraft cabin; energy consumption prediction

引言

民航客机在航前、航后及过站阶段使用机载 APU 提供飞机地面作业所必要的电力和空调供

应。从飞机的运行成本与安全、空气质量、噪音控制、甚至机坪拥堵角度分析, 使用地面专用设备替代飞机 APU 有很多的好处。但是使用地面专用空调设备, 飞机客舱的热舒适度差, 也不能实现能耗的最优, 究其根源在于不能正确评估飞机客舱的能耗需求, 以至于造成对地面专用空调设备控制的盲目性。所以为了正确评估飞机客舱的能耗需求, 需要对飞机客舱的能耗进行准确预测。



收稿日期: 2016-05-03 修回日期: 2016-07-14;
基金项目: 国家自然科学基金(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; 刘艳敏
(1990-), 女, 山东临沂, 硕士, 研究方向为非线性
系统建模。

飞机地面空调系统与飞机客舱构成的系统是一个复杂的热力学系统，还要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、非线性，很难精确的推导出系统的数学模型。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，预测需要采集很多现场的实时数据。但是廊桥的移动性、桥底铺设过多线缆带来的航空安全和维护等难题、飞机客舱和机身部位等数据采集不可能使用有线传输方式等问题使得数据的采集变得困难。人工神经网络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^[1-2]。但是传统的神经网络预测的精度不能满足实现控制效果的要求，而且其网络收敛速度较慢^[3-7]。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。协同微粒群优化算法的通用性强、计算简单，但是该优化算法的搜索性能比较依赖参数本身，因此不能够保证搜索到全局的最优解，容易陷入局部极小，而且搜索精度也不够高^[8]。

本文提出了一种改进的微粒群优化方法来优化神经网络的权值系数，将协同微粒群优化算法和混沌映射微粒群优化算法相结合。在执行协同优化算法时引入混沌思想，随着训练过程的进行慢慢降低微粒的寻优步长，同时在提前停止的微粒中加入混沌映射，使其重新回到整个解空间中。该方法有效的解决了协同优化算法在优化过程中出现的过早陷入局部极值，提前收敛导致无法获得全局最优值的问题。用该算法优化神经网络的参数，有效地提高了神经网络的收敛速度和预测精度，通过仿真验证了该预测方法的有效性。

1 改进协同微粒群优化算法

1.1 基本微粒群优化算法

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^[9]。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^[10]。

第 k 代的第 i 个微粒的速度更新公式为：

$$\begin{aligned} v_{id}(k+1) = & wv_{id}(k) + c_1 r(\cdot)[y_{id}(k) - x_{id}(k)] + \\ & c_2 r(\cdot)[y_{gd}(k) - x_{id}(k)] \end{aligned} \quad (1)$$

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； $r(\cdot) \in [0,1]$ 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。

第 k 代的第 i 个微粒的位置更新公式为：

$$x_i(k+1) = x_i(k) + v_i(k+1) \quad (2)$$

1.2 协同微粒群优化算法

本文所用的协同微粒群优化算法是带有信赖域方法和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，该算法采用了信赖域的方法调整搜索空间；同时在协同进化中，采用模糊 C 均值算法解决分组问题。

1.2.1 信赖域方法的自适应搜索范围调整

信赖域方法的思想可以理解为：在每一迭代点 x^k 处，先定义一个模型函数 $m_k(x)$ ，期望它在 x^k 的一个合适的领域内能很好地近似目标函数 f ，称这一领域为信赖域，定义为：

$$S = \{x \in \Re^n \mid \|x - x^k\|_k \leq \Delta_k\} \quad (3)$$

式中： Δ_k 为信赖半径； $\|\bullet\|_k$ 是依赖于迭代的一范数。在此信赖域之上，求 $m_k(x)$ 的一最优的试探步 s^k ，满足试探步 $x^k + s^k$ ，使 $m_k(\cdot)$ 减少且 $\|s^k\| \leq \Delta_k$ 。如果 $x^k + s^k$ 使 f 足够下降，则它被接受为下一迭代点 x^{k+1} 为 x^k ，减少 Δ_k 使信赖或缩小，以达到在新的信赖域上模型函数与目标函数有更好程度的近似。

1.2.2 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。模糊 C 均值聚类是一种典型的聚类方法，它主要优化的如下的目标函数：

$$J_m(U, V) = \sum_{k=1}^N \sum_{i=1}^C u_{ik}^m (x_k - v_k)^T (x_k - v_k) \quad (4)$$

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:

$$\sum_{k=1}^N u_{ik} > 0, \sum_{i=1}^C u_{ik} = 1, 0 \leq u_{ik} \leq 1, \\ i=1, 2, \dots, C; k=1, 2, \dots, N \quad (5)$$

隶属度和聚类中心可以通过如下迭代式目标函数最小:

$$u_{ik} = \frac{1}{\sum_{i=1}^C \left[\frac{(x_k - v_i)^T (x_k - v_i)}{(x_k - v_i)(x_k - v_i)^T} \right]^{\frac{1}{m-1}}} \\ i=1, 2, \dots, C; k=1, 2, \dots, N \quad (6)$$

$$v_i = \sum_{k=1}^N (u_{ik})^m x_k / \sum_{k=1}^N (u_{ik})^m; i=1, 2, \dots, C \quad (7)$$

通过迭代式(6)和(7)可获得目标函数较好地解。通过描述可看出, 模糊 C 均值聚类算法对初始聚类中心比较敏感, 随机初始化的聚类中心点可能会陷入局部最小, 所以需要改进算法, 本文在这之后引入了混沌思想, 可较好地克服这一早熟问题。

1.3 加入混沌思想改进的协同微粒群优化算法

本文采用的是 Logistic 混沌映射, 则微粒群的速度更新公式可写为:

$$v_{id}(k+1) = wv_{id}(k) \quad (8)$$

微粒群运动变为维持原速度的惯性运动, 因此粒子将沿直线方向搜索, 但是粒子直线寻找到最优解的可能性很小, 而且粒子有可能未达到最优解的时候已经减到零。所以在优化过程中向速度趋近于零的粒子引入随机白噪声, 克服微粒群优化算法粒子过早收敛的问题, 寻找到更有的解空间, 保持种群的搜素能力^[11]。即当 $v_i < v_{stop}$, 则:

$$v_{id}(k+1) = wv_{id}(k) + c_1 r(\cdot) [y_{id}(k) - x_{id}(k)] + \\ c_2 r(\cdot) [y_{gd}(k) - x_{id}(k)] + e_d \quad (9)$$

式中: e_d 是服从均值为 0、方差为 1 的高斯分布噪声。

对于符合 $v_i < v_{stop}$ 条件的 $m(m < N)$ 个粒子, 进行 Logistic 混沌映射, 并调整区间:

$$z_i^{n+1} = 4z_i^n(1 - z_i^n) \quad (10)$$

$$x_i = x_{min} + z_i^T (x_{max} - x_{min}) \quad (11)$$

式中: z_i^n 为 Logistic 的迭代映射参数; x_{min} 和 x_{max} 分别是粒子可能存在位置区间的最小值和最大值; n 是混沌迭代次数。通过式(10)和式(11)的调整, 让早熟的粒子在调整之后尽可能快的覆盖到整个解空间, 从而保证粒子能够持续全局搜索。

综上所述, 在带有信赖域方法和模糊聚类的协同微粒群优化算法的基础上, 加入 Logistic 混沌思想对原本的协同算法进行改进, 改进后的协同微粒群优化算法流程图如图 1 所示。

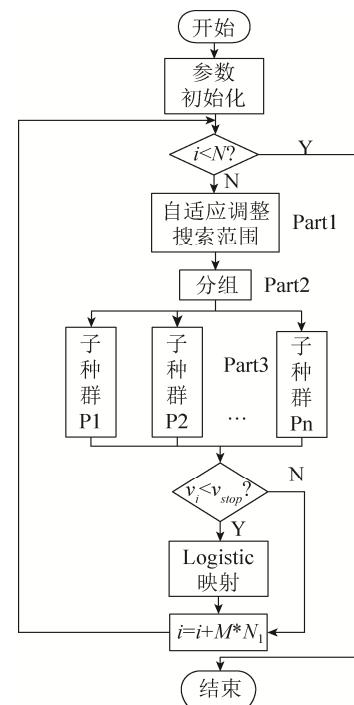


图 1 改进协同微粒群优化算法流程图

Fig. 1 Improved collaborative particle swarm optimization algorithm flow chart

图中, Part1 用信赖域的方法自适应的调整搜索范围; Part2 用模糊 C 均值聚类方法, 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; Part2 用动态邻域优化算法进行独立寻优, 同时循环 N_1 次。

2 飞机客舱能耗预测模型的建立

2.1 神经网络模型

本文选用 GRNN 神经网络预测方法, 因为它

在逼近能力和学习速度上较 RBF 神经网络有更强的优势，在样本数据较少时，预测效果也较好。GRNN 神经网络在结构上与 RBF 网络较为相似。它有四层构成，分别为输入层、模式层、求和层和输出层。对应的网络输入 $X = [x_1, x_2, \dots, x_n]^T$ ，其输出为 $Y = [y_1, y_2, \dots, y_k]^T$ 。

广义回归神经网络的理论基础是非线性回归分析，非独立变量 Y 相对于独立变量 x 的回归分析实际上是计算具有最大概率值的 $y^{[12]}$ 。设随机变量 x 和随机变量 y 的联合概率密度函数为 $f(x, y)$ ，已知 x 的观测值为 X ，则 y 相对于 X 的回归，即条件均值为：

$$\hat{Y} = E(y / X) = \frac{\int_{-\infty}^{\infty} y f(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \quad (12)$$

\hat{Y} 即为在输入为 X 的条件下， Y 的预测输出。

由样本数据集 $\{x_i, y_i\}_{i=1}^n$ 估算密度函数 $\hat{f}(X, y)$ ：

$$\begin{aligned} \hat{f}(X, y) = & \\ & \frac{1}{n(2\pi)^{\frac{p+1}{2}} \sigma^{p+1}} \sum_{i=1}^n \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \\ & \exp \left[-\frac{(X - Y_i)^2}{2\sigma^2} \right] \end{aligned} \quad (13)$$

其中： X_i 和 Y_i 为随机变量 x 和 y 的样本观测值； n 为样本容量； p 为随机变量 x 的维数； σ 为光滑因子。

用 $\hat{f}(X, y)$ 代替 $f(X, y)$ 整理计算可以得到网络的输出为：

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y_i \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right]} \quad (14)$$

2.2 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。本文通过 GRNN 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。

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。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 GRNN 预测模型。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

2.3 GRNN 预测模型参数优化

GRNN 模型结构相对比较简单，只有光滑因子 σ 这一个参数，使得网络结构设计的随意性大大降低了，因此由于人为选择模型参数的影响因素也最大限度的减少了。

事实上 σ 的选取和确定是一个优化问题，也就是寻找一个最优的 σ ，使得 GRNN 模型的训练输出值与实际值的均方差最小。目前主要采用手工调整的方法选取 σ 的值，这种方法存在效率低、精

度差的问题。本文采用改进的微粒群算法对 GRNN 模型进行优化, 先用信赖域的方法(式子 3 所示)自适应的调整搜索范围, 然后模糊 C 均值聚类算法进行分组, 通过迭代式(6)和(7)可以获得目标函数较好地解, 最后对解进行判断, 对早熟的粒子进行混沌映射, 通过式(10)和式(11)的调整, 让早熟的粒子在调整之后尽可能快的覆盖到整个解空间, 从而保证粒子能够持续全局搜索。

该优化算法大大提高了神经网络预测模型的预测精度, 优化结构图如图 2 所示。

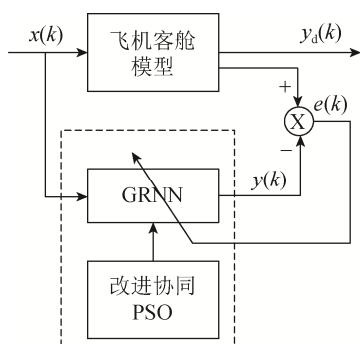


图 2 GRNN 预测模型参数优化结构图

Fig. 2 Structure diagram of parameter optimization of GRNN prediction model

GRNN 模型结构只有光滑因子 σ 这一个参数, 当光滑因子 σ 非常大的时候, $\hat{Y}(X)$ 近似于所有样本因变量的均值, 网络对样本数据的逼近过程就越平滑, 但误差也相应增大; 当光滑因子 σ 趋向于零的时候, $\hat{Y}(X)$ 和训练样本非常接近, 网络对样本的逼近能力就越强, 当需预测的点被包含在训练样本中时, 公式求出的预测值会和样本值非常接近, 但是一旦碰到样本中没有包含进去的点, 预测效果就会非常差。当光滑因子 σ 选取适中是, 使所有训练样本的因变量都被考虑进去, 能够提高预测精度。本文选用两种方法分别进行光滑因子 σ 的优化选取, 图 3 是采用改进的微粒群算法来优化光滑因子 σ 的结果, 由图中可以看出最佳适应值为 0.55; 图 4 是采用基本微粒群算法来优化光滑因子 σ 的结果, 由图中可以看出最佳适应值为 0.59。

由两图比较可以看出, 改进的微粒群优化算收

敛速度较基本微粒群优化算法要快, 在快速收敛的同时, 还避免了基本微粒群算法容易陷入局部机制的问题。

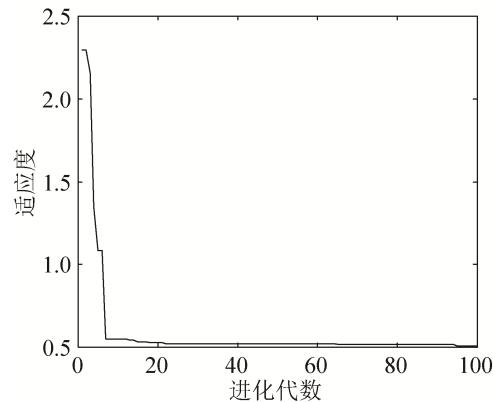


图 3 改进的微粒群算法优化神经网络参数
Fig. 3 Improved PSO algorithm for optimization of neural network parameters

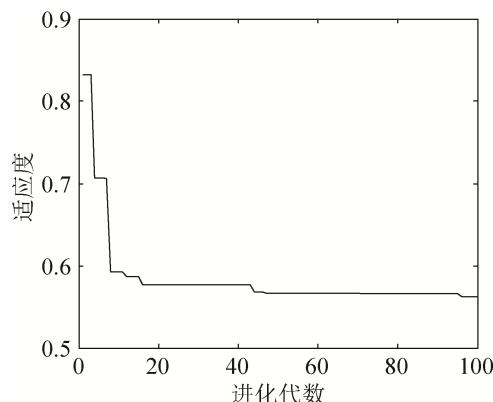


图 4 基本微粒群算法优化神经网络参数
Fig. 4 Optimization of neural network parameters by basic particle swarm optimization

3 仿真实验结果与分析

为了验证改进微粒群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。

为验证改进协同微粒群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(15)叠加 $K=0.1$ 的噪声信号, 每组样本数据产生 20 个测试样本, 总共得到 200 个测试样本。对于前 100 个样本作为训练集, 后 100 个样本作为测试集。

$$x_i = x_i + K\delta_f \times randn(1, 20) \quad (15)$$

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

选用两种方法取得的光滑因子 σ 的值进行 GRNN 神经网络的预测, 预测误差如图 5 所示。

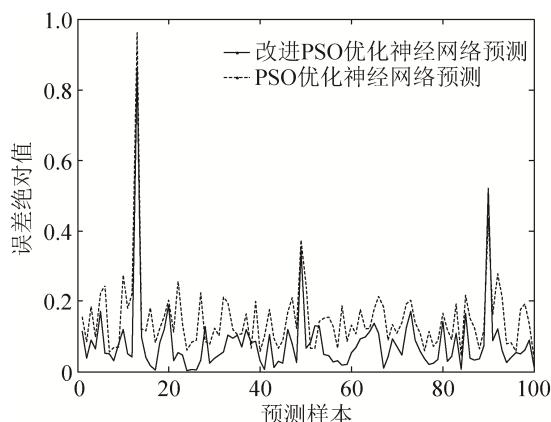


图 5 预测误差绝对值比较

Fig. 5 Comparison of absolute value of prediction error

由图 5 可知, 当单独采用基本微粒群优化方法来优化 GRNN 神经网络的参数时, 预测的误差绝对值在 0.2 左右, 预测的误差较大; 当采用改进的微粒群优化方法来优化 GRNN 神经网络的参数时, 预测误差降低到了 0.09 左右, 明显可以看出改进的微粒群优化方法使系统的预测精度得到了较好的提高。

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 6 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。

3.2 系统收敛性分析

为了验证改进方法的收敛效果, 将原始 BP 神经网络、微粒群优化 GRNN 网络、GRNN 网络和改进 PSO 优化 GRNN 网络进行比较仿真, 采用一致的网络初始条件进行训练, 结果如表 2 所示。由表 2 可知, 在训练了 8000 次以后, 本文所用的改

进 PSO 优化 GRNN 网络预测方法在学习误差和测试误差方面比其他的方法都减小了一个数量级。因此, 改进 PSO 优化 GRNN 网络预测方法在收敛速度和预测精度两方面得到了较好地提高。

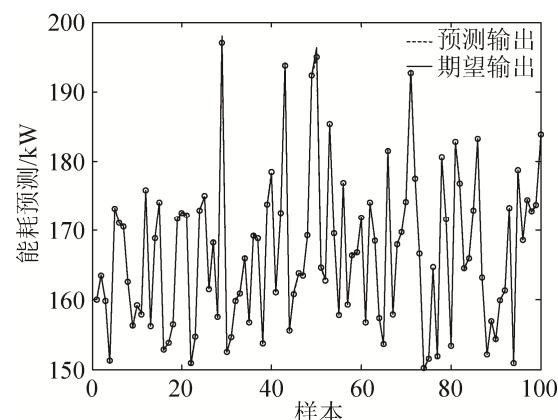


图 6 飞机客舱能耗预测输出

Fig. 6 Prediction output of aircraft cabin energy consumption

表 2 五种神经网络方法的比较

Tab. 2 Comparison of five neural network methods

神经网络	训练误差	泛化误差	时间/min
BPNN	0.080 5	0.213 01	14.36
PSO+GRNN	0.066 4	0.054 34	4.56
GRNN	0.071 7	0.046 02	31.22
改进 PSO+GRNN	0.000 4	0.000 29	4.68

由图 7 可以看出, 改进 PSO 优化 GRNN 网络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。

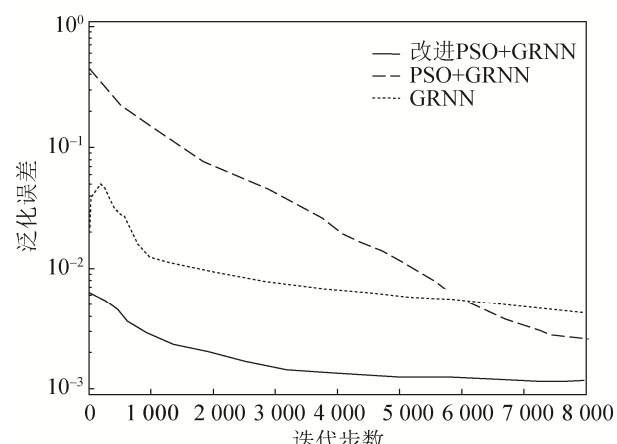


图 7 泛化误差收敛曲线的比较

Fig. 7 Comparison of generalized error convergence curves

4 结论

本文针对常规 GRNN 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, 提出了改进微粒群优化的 GRNN 网络参数的预测方法。该方法将协同微粒群优化算法和混沌映射微粒群优化算法相结合。将协同优化算法在优化过程中提前停止的微粒中加入混沌映射, 解决了优化过程提前收敛导致无法获得全局最优值的问题; 同时利用协同优化的收敛速度较快的优点是提高系统收敛速度。用该优化算法来优化 GRNN 网络的参数, 有效地提高了神经网络的收敛速度和预测精度。通过该方法建立的飞机客舱能耗预测模型, 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] 刘瑞叶, 黄磊. 基于动态神经网络的风电场输出功率预测[J]. 电力系统自动化, 2012, 36(11): 19-22.
Liu Ruiye, Huang Lei. Prediction of wind power output power based on dynamic neural network[J]. Power system automation., 2012, 36(11): 19-22.
- [2] 师彪, 李郁侠, 于新花, 等. 基于改进粒子群-模糊神经网络的短期电力负荷预测[J]. 系统工程理论与实践, 2010, 30(1): 157-166.
Shi Biao, Li Yuxia, Yu Xinhua, et al. Short-term load forecasting based on modified particle swarm optimizer and fuzzy neural network model [J]. Systems Engineering Theory & Practice, 2010, 30(1): 157-166.
- [3] 樊兆峰, 马小平, 邵晓根. 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 Zhaofeng, Ma Xiaoping, Shao Xiaogen. RBF neural network multi-step predictive control for nonlinear systems[J]. Control and Decision, 2014, 29(7): 1274-1278.
- [4] Zhang T, Chen Q. Novel air distribution systems for commercial aircraft cab-ins[J]. Building and Environment (S0360-1323), 2007, 42(4): 1675-1684.
- [5] 石欣, 张琦, 赵莹, 等. RC 热网络建筑能耗预测模型综述[J]. 仪器仪表学报, 2014, 35(12): 59-64.
Shi Xin, Zhang Qi, Zhao Ying, et al. Review of RC thermal network building energy consumption forecasting model[J]. Chinese Journal of Scientific Instrument, 2014, 35(12): 59-64.
- [6] 潘玉民, 邓永红, 张全柱. 短期电力负荷的小波—混沌时序预测[J]. 系统仿真学报, 2013, 25(5): 868-875.
Pan Yumin, Deng Yonghong, Zhang Quanhi. Wavelet-chaotic Time Series Prediction of short-term Electric Power Load [J]. Journal of System Simulation, 2013, 25(5): 868-875.
- [7] 李松, 刘力军, 谢永乐. 遗传算法优化 BP 神经网络的短时交通流混沌预测[J]. 控制与决策, 2011, 26(10): 1581-1585.
Li Song, Liu Lijun, Xie Yong le. Chaotic prediction for short-term traffic flow of optimized BP neural network based on genetic algorithm[J]. Control and Decision, 2011, 26(10): 1581-1585.
- [8] 李松, 刘立军, 翟曼. 改进粒子群算法优化 BP 神经网络的短时交通流预测[J]. 系统工程理论与实践, 2012, 32(9): 2045-2049.
Li Song, Liu Lijun, Zhai Man. Prediction for short-term traffic flow based on modified Pso optimized BP neural network[J]. Syatems Engineering Theory & Practice, 2012, 32(9): 2045-2049.
- [9] 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 Jianchao, Han Min. Model-structure analysis of dynamic neural networks with particle-swarm optimization [J].Control Theory & Applications, 2011, 28(9): 1075-1081.
- [10] 都延丽, 吴庆宪, 姜长生, 等. 改进协同微粒群优化的模糊神经网络控制系统设计[J]. 控制与决策, 2008, 23(12): 1327-1332.
Du Yanli, Wu Qingxian, Jiang Changsheng, et al. Improved cooperative particle swarm optimizer for design of fuzzy neural network control system [J].Control and Decision, 2008, 23(12): 1327-1332.
- [11] 窦春霞. 基于混沌神经网络模型的模糊预测控制及应用[J]. 系统仿真学报, 2002, 14(10): 1372-1375.
Dou Chunxia. Fuzzy Forecast Controller Based on Chaos Neural Network Model Research and Its Application [J]. Journal of System Simulation, 2002, 14(10): 1372-1375.
- [12] 黄金杰, 夏静, 满春涛, 等. 一种参数优化旋转广义回归神经网络模型[J]. 电机与控制学报, 2009, 13(3): 442-447.
Huang Jinjie, Xia Jing, Man Chuntao, et al. Parameter optimized rotated general regression neural network [J]. Electric Machines and Control, 2009, 13(3): 442-447.
- [13] 林家泉, 梁小贝, 陈维兴, 等. A320 飞机客舱热舒适性的数值模拟研究[J]. 流体机械, 2015, 43(5): 75-78.
Lin Jiaquan, Liang Xiaobei, Chen Weixing, et al. Numerical simulation study on thermal comfort of A320 aircraft cabin[J]. Fluid Machinery, 2015, 43(5): 75-78.