

# 改进灰色神经网络的作动系统功率预测

刘德鹏, 石 山

(空军工程大学航空航天工程学院,西安,710038)

**摘要** 为提高飞机上作动系统的功率预测精度,建立了改进的多变量灰色神经网络预测模型。考虑了对系统功率需求有较大影响的相关因素,采用主成分分析法提取综合变量作为输入,在提升准确性的基础上有效减少了输入维数;在利用递增方式对初始值进行选择的过程中,引入粒子群优化算法快速求解最优初始值和背景值,模型预测的平均误差由 13.35%降为 7.53%;考虑到序列波动对预测精度的影响,采用 BP 神经网络对预测值进行误差修正,进一步将模型的平均预测误差降为 4.07%。仿真实验表明,含主成分分析的改进灰色神经网络对飞机作动系统的功率有较高的预测精度,有利于飞机的电能调度。

**关键词** 主成分分析;改进灰色神经网络;作动系统;功率预测

**DOI** 10.3969/j.issn.1009-3516.2016.06.003

**中图分类号** V225;TP18 **文献标志码** A **文章编号** 1009-3516(2016)06-0012-06

## Power Prediction in Actuator System Based on Improved Grey Neural Network

LIU Depeng, SHI Shan

(Aeronautics and Astronautics Engineering College, Air Force Engineering University, Xi'an 710038, China)

**Abstract:** The accurate power prediction of actuator plays an important role in electric energy management. In order to improve the prediction accuracy in actuator system, an improved multivariable grey neural network model is established. Taken this aspect of the relative factors of producing a great impact on the needs of power in system into account, the PCA is used to extract the comprehensive variables as an input of the prediction model. By so doing, this effectively reduces the dimension on the basis of the accuracy of prediction. In the process of selecting the initial values and background values by utilizing the incremental method, the PSO is used to calculate the optimal background value to improve the prediction accuracy to a large degree. In addition, taken this aspect of the influence matter on sequence fluctuation into account, a BP neural network model is established to correct the error in the prediction value. The results show that the model is valid and advantageous to the energy dispatching of aircraft.

**Key words:** principal component analysis; grey neural network improved; actuator system; power prediction

随着多/全电技术的发展,驱动飞机舵面偏转的 液压作动系统逐渐由 EHA 和 EMA 取代<sup>[1-2]</sup>,有效

收稿日期:2016-01-12

作者简介:刘德鹏(1991—),男,山西广灵人,硕士生,主要从事飞机机电控制技术研究.E-mail:liudepengkgy@163.com.

**引用格式:**刘德鹏,石山.改进灰色神经网络的作动系统功率预测[J].空军工程大学学报:自然科学版,2016,17(6):12-17. LIU Depeng, SHI Shan. Power Prediction in Actuator System Based on Improved Grey Neural Network[J]. Journal of Air Force Engineering University: Natural Science Edition, 2016, 17(6): 12-17.

提升了系统的安全性和可靠性,但与此同时也给新一代飞机带来了严重的热管理问题<sup>[3]</sup>。传统的动力与热管理系统(Power and Thermal Management System, PTMS)不能综合作动系统的功率需求信息并对电能进行合理的调度<sup>[4-5]</sup>,因此,对作动系统的功率需求进行准确的预测,确保PTMS能够综合机上用电信息并形成最佳电能调度方案,对建立自适应动力与热管理系统(Adaptive Power and Thermal Management System, APTMS)、提高系统能量利用率、解除飞机热约束具有重要的作用<sup>[6-8]</sup>。

目前,常用的预测技术有时间序列预测技术、趋势外推预测技术、灰色预测技术等。其中,灰色预测技术以其较小的样本量,较高的预测精度被广泛应用。然而,传统GM(1,1)模型仅考虑原始序列数据及其内在规律,忽略了其他影响因素对功率的影响,导致模型的预测精度较低;此外,以原始数据序列的第一个数据值作为初值和通过紧邻等权法生成背景值的方法缺乏理论依据,也会在一定程度上降低模型的模拟精度和预测精度<sup>[9]</sup>。因此,要从本质上提高作动器功率预测的精度,需要考虑更多的影响因素,同时更加科学合理地选取初始值和背景值。此外,由于单一的预测算法有自身条件的限制,预测结果有一定的片面性和不稳定性,需要对预测结果进行误差修正。

本文在传统模型的基础上,建立了改进的GM(1,4)模型,采用主成分分析法(Principal Component Analysis, PCA)对特征数据进行特征提取,同时引入粒子群优化算法(Particle Swarm Optimization, PSO)求解最优的初始值和背景值,采用BP神经网络对预测误差进行修正,最终达到了在减少预测模型输入维数的同时提高预测精度的目标。

## 1 基于主成分分析的数据处理

影响作动系统功率需求的因素有高度、速度、风向、风速和舵面偏转角度等。为了在既减少灰色预测模型的输入变量个数、提高计算效率的情况下又不影响预测精度,采用主成分分析法将上述多维的相关联变量线性组合为低维不相关的综合变量,称为主成分。这些主成分的方差值大,能够尽可能多地反映原来变量的信息,同时也避免了重要信息的遗漏<sup>[10-11]</sup>。

### 1.1 主成分分析的基本原理

PCA一般从总体相关系数或协方差矩阵出发

来求解主成分。而在实际问题中,总体相关系数矩阵通常是未知的,因此需要通过样本数据进行估计。现设在数据集 $\mathbf{X}$ 中共有 $n$ 个样本,每个样本有 $p$ 个观测变量,则样本数据矩阵为:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} = [\mathbf{X}_1 \ \mathbf{X}_2 \ \cdots \ \mathbf{X}_p] \quad (1)$$

式中: $\mathbf{X}_i = (x_{1i}, x_{2i}, \dots, x_{ni})^T$ 。

对上述观测变量进行标准化:

$$z_{ij} = \frac{x_{ij} - \bar{x}_j}{\bar{s}_j} \quad (2)$$

式中: $\bar{x}_j$ 为第 $j$ 个观测变量的均值, $\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}$ ;  $\bar{s}_j$ 为第 $j$ 个观测变量的均方差, $\bar{s}_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2}$ ,标准化之后的指标数据满足 $E(Z_j) = 0$ 且 $D(Z_j) = 1$ 。

建立的标准化数据的相关系数矩阵为 $\mathbf{M} = (m_{ij})_{p \times p}$ ,矩阵中的每一个元素 $m_{ij}$ 反映了 $Z_i$ 和 $Z_j$ 的相关程度:

$$m_{ij} = \frac{\text{cov}(Z_i, Z_j)}{\sqrt{D(Z_i)} \sqrt{D(Z_j)}} \quad (3)$$

式中: $\text{cov}(Z_i, Z_j)$ 为 $Z_i$ 和 $Z_j$ 的协方差。由于标准化的 $Z_i$ 均值都等于0,方差都等于1,所以相关系数矩阵可用协方差矩阵求得:

$$\mathbf{R} = \frac{1}{n-1} \mathbf{Z}^T \mathbf{Z} \quad (4)$$

设 $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq L \geq \hat{\lambda}_p \geq 0$ 为 $\mathbf{R}$ 的 $p$ 个特征值,其对应的单位正交向量为 $\mathbf{A}_i = [a_{1i}, a_{2i}, \dots, a_{pi}]^T$ ,则 $p$ 个主成分为:

$$\begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \\ \vdots \\ \mathbf{F}_p \end{bmatrix} = \begin{bmatrix} a_{11} & a_{21} & \cdots & a_{p1} \\ a_{12} & a_{22} & \cdots & a_{p2} \\ \vdots & \vdots & & \vdots \\ a_{1p} & a_{2p} & \cdots & a_{pp} \end{bmatrix} \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_p \end{bmatrix} \quad (5)$$

式(5)等效于:

$$\mathbf{F} = \mathbf{A}^T \mathbf{X} \quad (6)$$

可以看出各主成分为相关因素的线性组合。虽然各主成分没有具体的物理含义,但是能够包含这些测量数据的所有信息。

设 $\omega_{i/p}$ 为第 $i$ 个成分 $F_i$ 对所有成分的贡献率:

$$\omega_{i/p} = \lambda_i / \sum_{j=1}^p \lambda_j \quad (7)$$

设 $\sum \omega_{i/p}$ 为前 $i$ 个成分 $F_i$ 对所有成分的累积

方差贡献率:

$$\sum \omega_{i/p} = \sum_{k=1}^i \lambda_k / \sum_{j=1}^p \lambda_j \quad (8)$$

一般来说,为了达到降维分析问题的目的,如果前  $q$  个主成分的累积方差贡献率  $\sum \omega_{i/p}$  达到 70%~90%,通常用前  $q$  个主成分替代原有的  $p$  个指标。

### 1.2 基于 PCA 的数据处理

本文采用某型飞机的相关测量数据,其测量值表示为  $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3, \mathbf{X}_4, \mathbf{X}_5]$ 。其中,风速  $\mathbf{X}_1$ , 风向  $\mathbf{X}_2$ , 速度  $\mathbf{X}_3$ , 高度  $\mathbf{X}_4$ , 升降舵偏转角度  $\mathbf{X}_5$ 。通过式(2)~(4)计算特征  $\lambda = [3.430\ 4, 1.656\ 2, 0.721\ 9, 0.449\ 8, 0]$ ,并最终得到主成分系数矩阵  $\mathbf{A} = (\hat{a}_1, \hat{a}_2, \hat{a}_3, \hat{a}_4, \hat{a}_5)$  如下:

$$\mathbf{Q} = \begin{bmatrix} 0.490\ 1 & -0.225\ 9 & 0.681\ 6 & -0.007\ 7 & 0.494\ 1 \\ 0.461\ 8 & -0.290\ 9 & -0.728\ 5 & 0.005\ 1 & 0.413\ 9 \\ 0.500\ 2 & 0.304\ 5 & -0.010\ 6 & -0.729\ 3 & -0.353\ 7 \\ 0.009\ 7 & 0.864\ 6 & -0.066\ 1 & 0.136\ 4 & 0.478\ 9 \\ 0.544\ 3 & 0.155\ 0 & 0.015\ 3 & 0.670\ 4 & -0.479\ 6 \end{bmatrix} \quad (9)$$

根据式(7)计算得出第 1~5 主成分的贡献率依次为 0.548, 0.265, 0.115, 0.072 和 0。由式(8)可知,前 3 个主成分的  $\sum \omega_{i/p}$  已经达到 92.8%。所以本文只用原始功率序列和 3 个主成分作为 GM(1, N) 的输入即可满足要求,即模型 GM(1, N) 中  $N$  的取值为 4。

## 2 改进的多变量灰色神经网络模型

### 2.1 GM(1, N) 的模型原理

为避免考虑相关因素较少对预测精度的造成的影响,选择 GM(1, N) 作为预测模型<sup>[12]</sup>,现对该模型的一般原理介绍如下<sup>[13]</sup>:

假设系统的特征数据序列  $y^{(0)}$  及相关因素序列  $x_i^{(0)}$  分别为:

$$\begin{cases} y^{(0)} = \{y^{(0)}(1), y^{(0)}(2), y^{(0)}(3), \dots, y^{(0)}(n)\} \\ x_i^{(0)} = \{x_i^{(0)}(1), x_i^{(0)}(2), x_i^{(0)}(3), \dots, x_i^{(0)}(n)\} \end{cases} \quad (10)$$

式中:  $n$  为序列长度,  $i$  为相关因素个数,  $i = 1, 2, \dots, N-1$ 。

对其进行一阶累加后,得到的生成数列为:

$$\begin{cases} y^{(1)} = \left\{ \sum_{k=1}^1 y^{(0)}(k), \sum_{k=1}^2 y^{(0)}(k), \dots, \sum_{k=1}^n y^{(0)}(k) \right\} \\ x_i^{(1)} = \left\{ \sum_{k=1}^1 x_i^{(0)}(k), \sum_{k=1}^2 x_i^{(0)}(k), \dots, \sum_{k=1}^n x_i^{(0)}(k) \right\} \end{cases} \quad (11)$$

新生成序列满足:

$$y^{(0)}(k) + az^{(1)}(k) = \sum_{i=1}^{N-1} b_i x_i^{(1)}(k) \quad (12)$$

式中:  $-a$  称为系统的发展系数,  $b_i$  称为系统的驱动系数,  $\mathbf{P}_N = [a \ b_1 \ \dots \ b_{N-1}]^T$  称为参数列,背景值为  $z^{(1)}(k) = \frac{1}{2}y^{(1)}(k) + \frac{1}{2}y^{(1)}(k-1)$ ,  $k=2, 3, \dots, n$ 。则模型可表示为  $y = \mathbf{B}\mathbf{P}_N$ , 用最小二乘法对  $\mathbf{P}_N$  进行估计有:

$$\mathbf{P}_N = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{y} \quad (13)$$

式中:

$$\mathbf{B} = \begin{bmatrix} -z^{(1)}(2) & x_1^{(1)}(2) & \dots & x_{N-1}^{(1)}(2) \\ -z^{(1)}(3) & x_1^{(1)}(3) & \dots & x_{N-1}^{(1)}(3) \\ \vdots & \vdots & & \vdots \\ -z^{(1)}(n) & x_1^{(1)}(n) & \dots & x_{N-1}^{(1)}(n) \end{bmatrix},$$

$$\mathbf{y} = [y^{(0)}(2) \ y^{(0)}(3) \ \dots \ y^{(0)}(n)]^T.$$

由此可得白化方程  $\frac{dy^{(1)}}{dt} + ay^{(1)} =$

$\sum_{i=1}^{N-1} b_i x_i^{(1)}(k)$  的时间响应序列为:

$$\hat{y}_1^{(1)}(k+1) = \left( y_1^{(1)}(0) - \frac{1}{a} \sum_{i=1}^{N-1} b_i x_i^{(1)}(k+1) \right) e^{-ak} +$$

$$\frac{1}{a} \sum_{i=1}^{N-1} b_i x_i^{(1)}(k+1) \quad (14)$$

其还原值为:

$$\hat{y}_1^{(0)}(k+1) = \hat{y}_1^{(1)}(k+1) - \hat{y}_1^{(1)}(k) \quad (15)$$

### 2.2 模型误差分析

由上述原理可知,模型中的背景值  $z^{(1)}(k)$  是由一次累加生成数列的紧邻等权方法生成的,该方法相当于把累积序列在区间上的连续函数等同为直线,而其实际上更应该近似为非线性规律,而且,对于不同的背景值,其权重  $\mu$  也不一定相同。因此,通过紧邻等权方法生成的背景值会使得预测模型存在一定的误差;另外,原模型是根据初始值  $y_1^{(0)}(0)$  求解时间响应式,这就意味着该点必定在预测曲线上,然而,最小二乘法原理并不要求拟合曲线必须过该点;同时考虑到  $(1, y_1^{(0)}(0))$  是特征序列中距离预测值最远的历史数据,与未来的关系并不密切,因而也就不能充分反映数据的发展趋势,这使得建立的模型与实际情况会存在较大的偏差。

实际上,当选择原始数列中的任何一个数据作为初始条件时,建立的模型都只能使序列中的某一点的拟合误差最小,而并不能保证这个模型对整个数列具有很好的模拟效果<sup>[14]</sup>。因此,为了减小模型的预测误差,我们还需要寻找一个最优初始值来提高预测精度。

### 2.3 改进的 GM(1, N) 模型

本文以作动系统功率需求的最小值和最大值为区间,通过递增方式改变初始值,在获得每个初始值的同时,以预测值和实际值误差平方和作为适应度函数,采用粒子群优化算法求解一组相应的最优背景值  $\{\mu_2, \mu_3, \dots, \mu_n\}$ ,最终取使适应度函数最小的初始值和背景值来建立预测模型。具体的求解过程描述如下:

**Step1** 取初始值为  $x_{\min}^{(0)}$ 。

**Step2** 对 PSO 初始化。设定加速度因子  $c_1$  和  $c_2$ , 惯性权重  $\omega$ 。算法的最大迭代次数  $k_{\max}$ , 当前进化代数  $k=1$ , 随机产生  $s$  个粒子, 其位置和速度向量分别为:

$$\mu_m = \{\mu_{m2}, \mu_{m3}, \dots, \mu_{mn}\}, v_m = \{v_{m2}, v_{m3}, \dots, v_{mn}\}$$

式中:  $m=1, 2, \dots, s$ 。

**Step3** 用适应值  $f(\mu_i)$  对种群进行评价。将  $\mu_m = \{\mu_{m2}, \mu_{m3}, \dots, \mu_{mn}\}$  代入式(13)得到参数列  $P_N$ , 通过式(14) ~ (15)得到原始数据的预测值  $\hat{y}^{(0)}(k)$ 。将 PSO 的适应度函数定义  $\min f(\mu_m) = \sum_{k=1}^n (\hat{y}^{(0)}(k) - y^{(0)}(k))^2$ ,  $f(\mu_m)$  就越小, 说明向量  $\mu_m$  用于灰色建模的适应性越好。

**Step4** 比较粒子的当前适应度值  $f(\mu_m)$  和自身历史最优位置  $p_m$  的适应度值  $f(p_m)$ , 如果  $f(\mu_m)$  小于  $f(p_m)$ , 则将粒子自身的历史最优位置设定  $\mu_m$ ; 否则, 粒子个体的历史最优位置不变。

**Step5** 比较粒子当前适应度值  $f(\mu_m)$  与种群全局最优位置  $p_g$  的适应度值  $f(p_g)$ , 如果  $f(\mu_m)$  小于  $f(p_g)$ , 则将粒子种群的全局最优位

置设定  $\mu_m$ ; 否则, 粒子种群的全局最优位置不变。

**Step6** 通过式(16)对粒子速度和位置更新:

$$\begin{cases} v_m^{k+1} = \omega v_m^k + c_1 r_1 (p_m^k - \mu_m^k) + c_2 r_2 (p_g^k - \mu_m^k) \\ \mu_m^{k+1} = \mu_m^k + v_m^k \end{cases} \quad (16)$$

**Step7** 检查算法是否满足迭代终止的条件。若终止条件满足, 则终止迭代求得最优值; 若不满足,  $k=k+1$  并返回 **Step2**。迭代终止设定为算法的迭代次数大于  $k_{\max}$  或者粒子群当前搜索到的最优位置满足预定最小适应阈值。

**Step8** 把上述粒子群算法求出的最优值及其相应的适应值记录并保存。

**Step9** 给初始值  $x$  增加一个大于零的量, 即  $x \leftarrow x_{\min}^{(0)} + \delta$ , 重复上述过程, 直至  $x = x_{\max}^{(0)}$ 。

最终, 得到不同初值下预测值与实际值的最小离差平方和, 取使得离差平方和最小的背景值和初值建立模型。

### 2.4 BP 神经网络误差修正

作动系统需求功率序列一方面具有一定的规律性, 另一方面也具有很强的随机性, 用单一的 GM(1, 4) 模型只能拟合出系统的非线性, 而对数据非平稳性的预测结果则不太理想<sup>[15]</sup>。所以, GM(1, 4) 预测模型会存在一定的误差, 而且这种预测误差是受序列波动影响的, 一般来说, 序列波动较大处的预测偏差往往比较大<sup>[16]</sup>。因此, 要对作动系统的功率进行准确预测, 有必要考虑序列波动对预测误差的影响, 建立误差修正模型对 GM(1, 4) 的预测值进行修正。对此, 建立了基于 BP 神经网络的误差修正模型, 具体的预测过程见图 1。

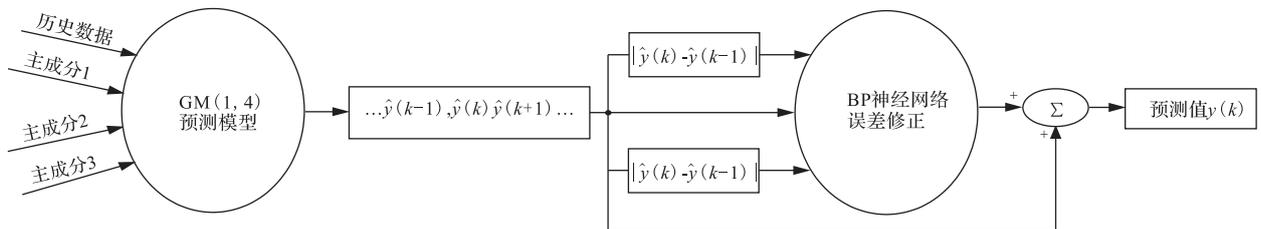


图 1 预测过程示意图

Fig.1 Scheme for forecasting process

## 3 仿真实验

以某型飞机为例进行验证, 每 1 min 对该飞机升降舵作动系统的功率需求采样一次。截取离当前时刻最近的数据序列建立预测模型, 预测作动系统

未来 10 min 功率需求。首先验证改进 GM(1, 4) 模型的有效性, 记传统模型为模型 1, 改进 GM(1, 4) 模型为模型 2, 设作动系统功率范围为  $[0, 2000]$ , 固定增量  $\delta$  为 20, 在选取主成分作为模型输入后, 对其预测效果进行比较, 见图 2。

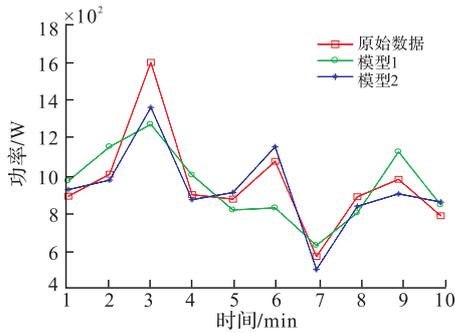


图2 模型1和模型2功率预测对比图

Fig.2 Comparison of power prediction between model 1 and model 2

从图中可以看出,改进 GM(1,4)模型的预测精度较传统模型有很大提高,但仍然存在一定程度上的误差,尤其在序列波动较大的地方较为明显。所以,单纯依靠改进 GM(1,4)模型的拟合效果难以满足作动系统功率预测精度高的要求。

为使模型的预测精度进一步提高,对改进 GM(1,4)模型进行采用 BP 神经网络进行修正,其中,BP 神经网络的激活函数采用 Sigmoid 函数,输入层和隐含层则使用 Tansig 传递函数,输出层采用 Logsig 函

数,学习速率为 0.2,网络全局误差为 0.005,最大训练步数为 1 000,隐含层设为 1 层,确定隐含层节点数定为 7 个,输出为预测误差,记此模型为模型 3,将其预测效果与模型 2 对比,从图 3 中可以看出,考虑了序列波动影响的误差修正使得预测效果有了很大的改善。

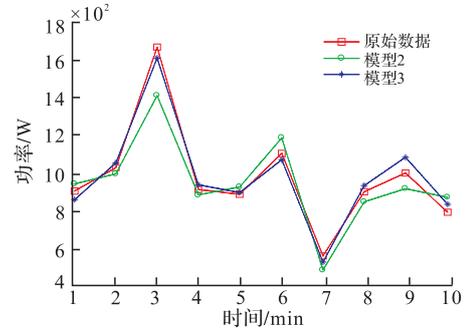


图3 模型2和模型3功率预测对比图

Fig.3 Comparison of power prediction between model 2 and model 3

现将上述 3 种模型的对未来 10 个时刻的预测结果及相对误差进行量化计算,统计见表 1。

表 2 作动系统功率预测结果表

Fig.2 Scheme for forecasting results of actuator system

相对时刻	实际值/W	模型 1		模型 2		模型 3	
		预测值/W	相对误差 %	预测值/W	相对误差 %	预测值/W	相对误差 %
1	899.6	986.8	9.69	938.2	4.29	855.4	4.91
2	1 023.7	1 180.3	15.30	989.5	3.34	1 047.9	2.36
3	1 654.8	1 308.5	20.93	1 399.7	15.42	1 597.2	3.48
4	908.7	1 018.9	12.13	879.3	3.24	933.1	2.69
5	883.1	822.2	6.90	922.6	4.47	891.4	0.93
6	1098.5	835.6	23.93	1 178.5	7.28	1 066.2	2.94
7	563.0	624.5	10.92	487.2	13.46	527.8	6.26
8	896.3	805.4	10.14	845.9	5.62	928.1	3.55
9	995.9	1 149.5	15.42	913.4	8.28	1 079.5	8.39
10	789.3	853.7	8.16	867.1	9.86	830.6	5.23
平均误差		—	13.35	—	7.53	—	4.07

从表中可以看出,基于误差修正的改进 GM(1,4)模型只在个别点上的预测精度比模型 2 差,但在整体上能有效减小预测误差,其在波动最大的峰值点(3,1 654.8)处的相对误差为 3.48%,其他点的最大相对误差为 8.39%,平均相对误差为 4.07%,较另外 2 个模型在预测精度上有很大的提高,因而能够满足作动系统功率预测需求。同时不难看出,模型在后期的预测精度有所下降,说明选择建立模型的原始数据与未来数据发展趋势的相关性减小,为保证预测精度,可选择用每个模型预测未来 7 个时刻的数据,然后利用最新数据建立模型进行下一步的

预测。

#### 4 结语

本文提出一种主成分分析—改进灰色神经网络的飞机作动系统功率预测方法,在利用 PCA 有效综合飞机作动系统功率影响因素,减少 GM(1, N) 预测模型的输入维数的基础上通过 PSO 算法对 GM(1,4)模型初始值和背景值的选择方法进行改进。同时,分析序列波动对 GM(1,4)模型的预测精度的影响,并采用 BP 神经网络对该因素造成的误差进

行修正,最终证明上述方法能够减小模型的预测误差,可以有效提升作动系统功率预测的能力。

#### 参考文献(References):

- [1] MCCORMICK B. Electronics for Advanced Electromechanical Actuators Design Considerations[C]// IEEE Proceedings of the National Aerospace and Electronics Conference 1985. New York: Institute of Electrical and Electronics Engineers Inc, 1985: 604-610.
- [2] SERGEYE L. Electromechanical Flight Actuators for Advanced Flight Vehicles[J]. IEEE Trans AES, 1999, 35(2): 511-518.
- [3] 严仰光,秦海鸿,龚春英,等.多电飞机与电力电子[J].南京航空航天大学学报,2014,46(1):11-18.  
YAN Yangguang, QIN Haihong, GONG Chunying, et al. More Electric Aircraft and Power Electronics[J] Journal of Nanjing University of Aeronautics & Astronautics, 2014, 46(1): 11-18. (in Chinese)
- [4] O'CONNELL Tim, RUSSELL Greg, MCCARTHY Kevin, et al. Energy Management of an Aircraft Electrical System[C]//46th AIAA /ASME/SAE/ASEE Joint Propulsion Conference & Exhibit. Nashville: AIAA, 2010: 22-26.
- [5] FRENCH Mathew, KUHN Frederick, BERGMAN Suzanne. System Architecture Studies for the Energy Optimized Aircraft [R]. AIAA, 2013-0882.
- [6] ERIC A, STEVE I, KEVIN Mccarthy, et al. Invent, Modeling, Simulation, Analysis and Optimization [M]. Florida: AIAA Aerospace Sciences Meeting Including the New Horizons Forum and Aerospace Exposition, 2010.
- [7] O'CONNELL T, RUSSELL G, MCCARTHY K, et al. Energy Management of Aircraft Electrical System [C]//48th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit, 2010.
- [8] 于喜奎,王伟.飞机综合机电系统热管理技术浅析[J].飞机设计,2006,(2):60-62.  
YU Xikui, WANG Wei. The Analysis of Thermal Management Techniques for Onboard Integrated Mechanical-Electronic Systems[J]. Aircraft Design, 2006 (2): 60-62. (in Chinese)
- [9] 马洪松.基于改进灰色模型的电力负荷预测方法研究及应用[D]保定:华北电力大学,2013.
- MA Hongsong. Research and Application of Power Load Forecasting Method Based on Improved Grey Model[D]. Baoding: North China Electric Power University, 2013. (in Chinese)
- [10] JOLLIFFE T. Principal Component Analysis [M]. 2th ed. New York: Springer, 2002.
- [11] NOUNOU M N, BAKSHI B R, SHEN Xiaotong. Improving Principal Component Analysis Bayesian Estimation[C]// Proceedings of the American Control Conference Arlington, VA June 25~27, 2001, 5:3666-3671.
- [12] 王守相,张娜.基于灰色神经网络组合模型的光伏短期出力预测[J].电力系统自动化,2012,36(19):37-41.  
WANG Shouxiang, ZHANG Na. Short-Term Output Power Forecast of Photovoltaic Based on a Grey and Neural Network Hybrid Model[J]. Automation of Electric Power System, 2012, 36(19): 37-41. (in Chinese)
- [13] XU Sheng, ZHAO Huifang, LV Xuanli. Grey SVM Based Model for Patent Application Filings Forecasting[C]//IEEE International Conference on Fuzzy Systems, 2008: 4630369.
- [14] 王忠桃.灰色预测模型相关技术研究[D].成都:西南交通大学,2008.  
WANG Zhongtao. Research on Technique of Grey Prediction Model [D]. Chengdu: Southwest Jiaotong University, 2008. (in Chinese)
- [15] 陈永红,张大发,王悦民,等.基于灰色马尔科夫组合模型的管道腐蚀速率预测方法[J].核动力工程,2009,30(2):95-98.  
CHEN Yonghong, ZHANG Dafa, WANG Yuemin, et al. Prediction of Pipeline Corrosion Rate Based on Grey Markov Models[J]. Nuclear Power Engineering, 2009, 30(2): 95-98. (in Chinese)
- [16] 张书豪.基于改进灰色神经网络的污染物排放量预测建模及实现[D].成都:电子科技大学,2013.  
ZHANG Shuhao. The Prediction of Pollutants' Emissions Modeling and Implementation Based on Improved Gray Neural Network [D]. Chengdu: University of Electronic Science and Technology of China, 2013. (in Chinese)

(编辑:姚树峰)