

文章编号:1674-8190(2022)06-166-07

# 基于GRA-IPSO-SVM的航材携行需求预测研究

李黄琪<sup>1</sup>, 蔡开龙<sup>2</sup>, 郝明<sup>3</sup>, 薛红阳<sup>1</sup>, 濮志刚<sup>1</sup>, 何森<sup>1</sup>

(1.南昌航空大学 飞行器工程学院, 南昌 330063)

(2.南昌航空大学 通航学院, 南昌 330063)

(3.空军工程大学 航空机务士官学院, 信阳 464000)

**摘要:** 异地执行飞行任务中航材需求的准确预测是做好携行保障的主要内容之一,为此提出灰色关联分析(GRA)与改进粒子群优化(IPSO)算法及支持向量机(SVM)相结合的航材预测方法。首先运用GRA对航材携行需求的影响因素进行分析;其次引入活性因子和非线性惯性系数改进粒子群优化算法,并通过IPSO对SVM参数进行寻优;最后使用优化后的SVM模型预测航材需求。结果表明:基于GRA-IPSO-SVM的航材预测方法预测的均方根误差比基于PSO-SVM的预测方法下降0.16,平均绝对百分比误差下降2.18%,预测时间减少0.7 s。

**关键词:** 航材;灰色关联度;支持向量机;改进粒子群算法;需求预测

中图分类号: V267

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.2022.06.18

开放科学(资源服务)标识码(OSID):



## Research on Forecasting of Aviation Material Carrying Demand Based on GRA-IPSO-SVM

LI Huangqi<sup>1</sup>, CAI Kailong<sup>2</sup>, HAO Ming<sup>3</sup>, XUE Hongyang<sup>1</sup>, PU Zhigang<sup>1</sup>, HE Sen<sup>1</sup>

(1. School of Aircraft Engineering, Nanchang Hangkong University, Nanchang 330063, China)

(2. College of Aviation, Nanchang Hangkong University, Nanchang 330063, China)

(3. College of Air Cadet, Air Force Engineering University, Xinyang 464000, China)

**Abstract:** Accurate prediction of aviation material requirements for off-site missions is one of the main elements of a good trip assurance, therefore, the method combining gray relation analysis (GRA), improved particle swarm optimization (IPSO) algorithm and support vector machine (SVM) is proposed for predicting aviation material. Firstly, GRA is applied to analyze the factors influencing the demand for aviation materials carrying. Secondly, the particle swarm optimization algorithm is improved by introducing activity factors and non-linear inertia coefficients, and the SVM parameters are optimized by IPSO. Finally, the optimized SVM model is used to predict the demand for aviation materials. The results show that, the root mean square error predicted by aviation material prediction method based on GRA-IPSO-SVM is decreased by 0.16 than that of by using the method based on PSO-SVM, the mean absolute percentage error is decreased by 2.18%, and the prediction time is decreased by 0.7 s.

**Key words:** aerospace materials; gray relation analysis; support vector machine; improved particle swarm optimization algorithm; demand forecasting

收稿日期: 2021-12-21; 修回日期: 2022-02-20

基金项目: 空装重点项目(KJ2019A030138)

通信作者: 蔡开龙, 70692@nchu.edu.cn

引用格式: 李黄琪, 蔡开龙, 郝明, 等. 基于GRA-IPSO-SVM的航材携行需求预测研究[J]. 航空工程进展, 2022, 13(6): 166-172.

LI Huangqi, CAI Kailong, HAO Ming, et al. Research on forecasting of aviation material carrying demand based on GRA-IPSO-SVM[J]. Advances in Aeronautical Science and Engineering, 2022, 13(6): 166-172. (in Chinese)

## 0 引言

航材携行保障工作是航空兵战斗力的重要组成部分。近年来,随着异地执行飞行任务的增多,转场携行保障不可避免。特别是持续时间长、任务强度大的需要异地执行的专项任务以及重大演习任务等,都需要不断提高航材携行保障能力,其中对任务中航材需求进行准确预测是做好携行保障的主要内容之一<sup>[1]</sup>。

航材的需求预测是一个系统预测过程,是一项科学的定性分析与量化表示相结合的工作<sup>[2]</sup>。航材需求的预测方法有很多,其中时间序列预测法<sup>[3-5]</sup>是早期使用的航材预测方法。毕钊等<sup>[6]</sup>综合考虑季节变动、中长期趋势以及随机干扰等因素之间的相互作用,改善时间序列法短期预测精度不高的问题,但考虑的因素太少且长期预测误差较高;J. D. Croston<sup>[7]</sup>则考虑了时间间隔与消耗历史等因素,基于指数平滑法提出Croston方法用于航材预测,但现实中很多需求都不符合正态分布,因此该方法预测精度也不高;R. H. Teunter等<sup>[8]</sup>使用英国皇家空军的大型数据集,将Bootstrap法用于预测间断型航材需求量,但在预测小样本集航材需求时效果不佳。由于人工智能算法的兴起,尚琦坤等<sup>[9]</sup>采用遗传算法优化灰色神经网络来预测航材需求,考虑了多因素下的航材需求预测,但训练网络模型时间较长;曾浩然等<sup>[10]</sup>提出支持向量机回归模型来预测航材消耗量,该方法对小样本数据有很好的适应性,但是支持向量机参数的不同也会影响预测精度;孙绳山等<sup>[11]</sup>利用粒子群算法对支持向量机参数进行寻优,提高了支持向量机预测的稳定性,但粒子群算法容易陷入局部最优,降低预测精度。综上所述,航材携行需求预测面临的问题有影响因素冗余、预测时间长和预测误差大等。

针对这些问题,本文提出基于GRA-IPSO-SVM的航材预测方法对航材携行需求进行预测。该方法采用GRA对航材携行需求的影响因素进行分析,提取关联度高于0.75的影响因素作为预测模型的输入;通过引入活性因子和非线性惯性系数改进粒子群优化算法;利用改进的粒子群优化(IPSO)算法对SVM的参数进行寻优,并将最优解带入SVM进行预测;通过仿真对比基于PSO-

SVM、GRA-PSO-SVM和GRA-IPSO-SVM三种预测方法预测的均方根误差、平均绝对百分比误差和模型消耗时间。

## 1 航材携行影响因素分析

任务中航材携行情况直接或间接受多种因素影响,且一定程度上各因素之间也会相互作用。航材携行的影响因素可以分为航材自身影响因素、任务影响因素、环境影响因素和人员影响因素<sup>[1]</sup>,航材携行影响因素分析如表1所示。任务影响因素有飞行时长和起落架次,飞行时长和起落架次都会加剧航材的消耗;航材自身影响因素主要为航材的失效率,失效率是执行任务时航材发生严重故障或失效的平均概率;环境影响因素包括执行任务中飞行环境的平均温度和平均湿度,环境造成的差异也会加剧航材的消耗,而且也会影响飞行人员和维修人员的工作状态进而影响航材消耗;人员影响因素主要有飞行人员和维修人员能力水平,飞行人员和维修人员能力水平越高,越能够减少不必要的损失,该因素可以通过飞行(维修)时长、失误次数、人员等级等因素运用模糊层次分析法计算得到<sup>[12]</sup>。

表1 航材携行影响因素分析表

Table 1 Analysis of factors influencing the carriage of aviation materials

符号	影响因素	数值类型	取值
$x_1$	飞行时长	小时	任务期间任务飞行的总时间
$x_2$	起落架次	次数	任务期间飞机起落的总架次
$x_3$	失效率	数值	根据相关记录计算获得
$x_4$	平均温度	摄氏度	查阅资料获得
$x_5$	平均湿度	湿度值	查阅资料获得
$x_6$	人员因素	综合量化值	计算获得

## 2 航材携行需求预测方法

### 2.1 GRA分析

为提高航材携行需求量预测的准确性,本文采用灰色关联分析(GRA)选出关联度高的影响因素带入预测模型。选取影响因素 $X=[x_1, x_2, \dots, x_i]$ ,  $m=1, 2, \dots, i$ ,  $X$ 为自变量,航材携行需求量 $Y$ 为因变量,计算各因素与航材携行需求量之间的灰色关联度<sup>[12]</sup>。

(1) 为消除量纲的影响,将数据归一化。

(2) 计算各因素关联系数 $\xi_i(K)$ ,公式为

$$\xi_i(k) = \frac{\min_i \min_n |y(k) - x_m(k)| + \rho \max_i \max_n |y(k) - x_m(k)|}{|y(k) - x_m(k)| + \rho \max_i \max_n |y(k) - x_m(k)|} \quad (k = 1, 2, \dots, n) \quad (1)$$

式中: $\rho$ 为分辨系数; $n$ 为案例个数。

(3) 计算各影响因素的灰色关联度。

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k) \quad (2)$$

(4) 比较并选择关联度高的影响因素。

## 2.2 SVM 预测模型

设航材携行样本数据  $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$ , 航材需求数  $Y = [y_1, y_2, \dots, y_n]$ , 影响因素  $X = [x_1, x_2, \dots, x_n]$ 。采用 SVM 拟合一个与  $Y$  相近的回归函数:

$$f(X) = \omega \varphi(X) + b \quad (3)$$

式中: $\omega$ 为权值向量; $\varphi(X)$ 为映射函数; $b$ 为偏置。

SVM 算法通过求解下述问题确定  $\omega$  和  $b$ <sup>[13]</sup>:

$$O = \min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4)$$

$$\text{s.t.} \begin{cases} y_i - \omega \varphi(X) - b \leq \varepsilon + \xi_i \\ \omega \varphi(X) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

式中: $C$ 为惩罚因子, $C > 0$ ; $\varepsilon$ 为容许误差; $\xi_i, \xi_i^*$ 为松弛变量。

通过在公式(4)中引入 Lagrange 函数,再利用对偶原理将上述优化问题转化为

$$O = \max \left[ -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\lambda_i - \lambda_i^*) (\lambda_j - \lambda_j^*) \varphi(x_i) \cdot \varphi(x_j) + \sum_{i=1}^n (\lambda_i - \lambda_i^*) y_i - \sum_{i=1}^n (\lambda_i - \lambda_i^*) \varepsilon \right] \quad (5)$$

$$\text{s.t.} \begin{cases} \sum_{i=1}^n (\lambda_i - \lambda_i^*) = 0 \\ 0 \leq \lambda_i \leq C, 0 \leq \lambda_i^* \leq C \end{cases}$$

式中: $\lambda_i, \lambda_i^*$ 为拉格朗日乘子,且 $\lambda_i > 0, \lambda_i^* > 0$ 。

设由式(3)得到的最优解<sup>[14]</sup>为 $\alpha_i = [\alpha_1, \alpha_2, \dots, \alpha_n], \alpha_i^* = [\alpha_1^*, \alpha_2^*, \dots, \alpha_n^*]$ ,然后依照 KKT 最优化条件,并采用核函数 $K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j)$ ,推导出非线性回归函数的表达式如下:

$$k_{\text{RBF}}(x_i, x_j) = \exp[-g(x_i - x_j)^2] \quad (6)$$

$$\omega^* = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \varphi(x_i) \quad (7)$$

$$\begin{cases} b = y_i - \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x_j) + \varepsilon \\ b = y_i - \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x_j) - \varepsilon \end{cases} \quad (8)$$

$$f(x) = \omega^* K(x_i, x_j) + b \quad (9)$$

本文选用径向基核函数(RBF)公式为

$$k_{\text{RBF}}(x_i, x_j) = \exp[-g(x_i - x_j)^2] \quad (10)$$

式中: $g$ 为核函数方差, $g = 1/2\delta^2$ 。

## 2.3 IPSO 算法

粒子群优化算法是一个传统的寻优算法<sup>[15]</sup>,但采用传统的粒子群优化算法求解问题时容易陷入局部最优解,将局部最优解带入预测模型会导致预测结果偏差较大。基于这一问题,本文引入活性因子和非线性惯性系数,提出一种改进的粒子群优化(IPSO)算法。

设在可行解空间  $N$  中随机初始化  $m$  个粒子构成的种群  $x = \{x_1, x_2, \dots, x_m\}$ , 第  $i$  个粒子所处的位置  $x_i = \{x_{i1}, x_{i2}, \dots, x_{in}\}$ , 粒子移动速度  $v_i = \{v_{i1}, v_{i2}, \dots, v_{in}\}$ 。根据目标函数计算每一个粒子的适应度值。在每一次迭代更新过程中,粒子将跟踪个体搜索到的最优解  $P_{\text{id}}$  和种群搜索到的最优解  $P_{\text{gd}}$ 。当两个最优解都找到后通过对比  $P_{\text{id}}$  和  $P_{\text{gd}}$  决定是否更新,通过不断地迭代更新自身的位置和速度来寻求最优解<sup>[16-17]</sup>。

(1) 引入活性因子

为增强粒子摆脱局部最优继续搜索全局最优点的的能力,引入活性因子以提高粒子全局寻优性能。在  $P_{\text{id}}$  前乘系数  $\alpha$ ,当解空间维数  $N \leq 2$  时  $\alpha = 1.2$ ,当解空间维数  $N > 2$  时  $\alpha = 2$ 。粒子的位置和速度的更新公式如式(11)~式(12)所示。

$$v_{in}(t+1) = \omega v_{in}(t) + c_1 \text{rand}(\cdot) [\alpha P_{id} - x_{in}(t)] + c_2 \text{rand}(\cdot) [\alpha P_{gd} - x_{in}(t)] \quad (11)$$

$$\text{s. t. } \begin{cases} \alpha = 1.2 & (n \leq 2) \\ \alpha = 2.0 & (n > 2) \end{cases}$$

$$x_{in}(t+1) = x_{in}(t) + v_{in}(t+1) \quad (12)$$

式中:  $t$  为当前迭代次数;  $x_{in}(t+1)$ ,  $v_{in}(t+1)$  为第  $i$  个粒子在  $t+1$  次迭代中在第  $N$  维上的位置和速度;  $\omega$  为惯性系数;  $c_1$  和  $c_2$  为学习因子;  $\text{rand}(\cdot)$  为  $[0, 1]$  区间的随机数。

(2) 引入非线性惯性系数

为改进  $\omega$  为定值对算法全局搜索带来的副作用, 本文引入非线性惯性系数, 在计算前期降低其收敛速度, 提高粒子群全局搜索能力, 在算法后期提高收敛速度, 减少寻优时间, 计算过程如公式 (13) 所示。

$$\omega = \pi \left[ \left( \frac{i}{i_{\max}} \right)^2 - \frac{i}{i_{\max}} \right] + 1 \quad (13)$$

式中:  $i$  为当前迭代次数;  $i_{\max}$  为最大迭代次数。

### 3 航材携行需求分析流程

首先采用 GRA 选出与航材携行需求关联度高的影响因素, 其次运用 IPSO 算法对 SVM 模型的惩罚因子  $C$  和核参数  $g$  进行参数寻优, 最后将最优

的惩罚因子  $C$  和核参数  $g$  带入 SVM 模型进行航材携行需求预测, 本文的具体流程如图 1 所示, 主要步骤如下:

Step 1: 将数据进行归一化处理;

Step 2: 使用 GRA 选择关联度高的影响因素;

Step 3: 导入数据, 划分训练集和测试集;

Step 4: 进行 SVM 模型的训练与验证;

Step 5: 设置 SVM 模型的交叉验证均方差值为适应度值;

Step 6: 引入活性因子和非线性惯性系数, 初始化 IPSO 算法的相关参数;

Step 7: 计算粒子的适应度值, 适应度值越小则代表该粒子的位置越好;

Step 8: 生成粒子个体最优位置和粒子种群全局最优位置, 如果个体最优位置优于全局最优位置, 则用  $P'_{id}$  替代  $P'_{gd}$ ;

Step 9: 根据式 (11)~式 (13) 更新粒子的位置和速度;

Step 10: 判断是否到达最大迭代次数, 如果达到则计算结束, 输出最优  $C$  和最优  $g$ ; 如果未达到则重复 Step 7;

Step 11: 将 IPSO 搜索的最优参数代入 SVM 模型重新训练, 得到优化后的 SVM 模型; 将优化后的 SVM 模型进行航材预测。

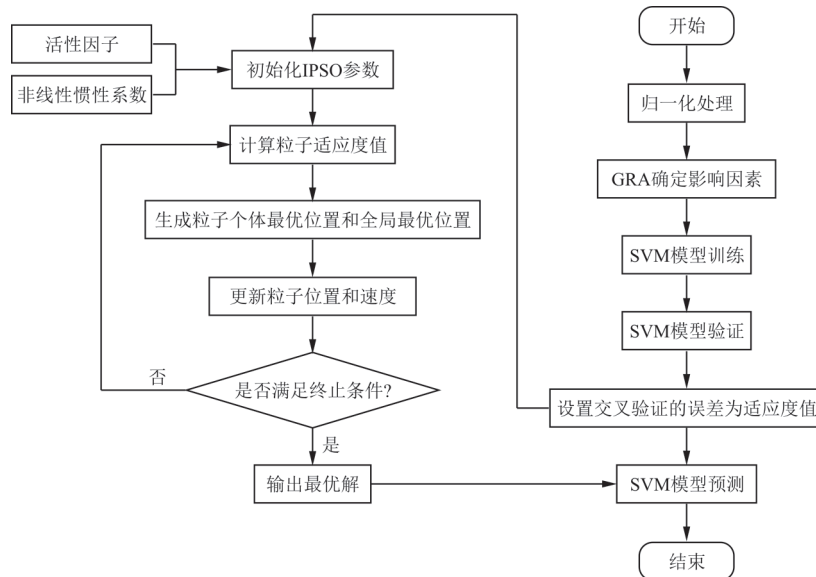


图 1 总流程图

Fig. 1 General flow chart

## 4 案例分析

### 4.1 参数设置

选取空军某飞机航材保障部队在执行过去 32 次转场保障任务中某项携行航材的相关数据,如表 2 所示。先取前 20 组数据作为训练集进行训练,剩余 12 组数据作为测试集对训练出的模型进行测试。本文实验平台是 Windows 10 操作系统, Intel(R) Core(TM) i5-10500 CPU@3.10 GHz, 32 GB RAM; 开发环境是 Matlab 2019a, Lib SVM(3.24)。

表 2 某项携行航材的相关数据  
Table 2 Data related to a certain portable material

任务	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	需求
1	94	27	5.4	3	76	0.214	8
2	112	35	6.8	34	21	0.391	9
3	83	25	7.1	0	88	0.195	7
...	...	...	...	...	...	...	...
30	148	40	7.2	8	48	0.664	10
31	128	38	6.2	15	46	0.605	9
32	88	26	5.2	1	82	0.347	7

GRA 中分辨系数  $\rho = 0.5$ ; 在采用 SVM 模型进行航材预测时, 选用默认的 RBF 核函数, 交叉验证次数为 5 次; IPSO 算法终止迭代次数设置为 100, 种群规模数量设置为 20, 学习因子  $c_1 = 1.5$ 、 $c_2 = 1.7$ ; SVM 参数都设置为区间 (0, 100), 其他设置为默认值; PSO 算法设置  $\omega = 0.9$ , 其余参数与 IPSO 算法相同。

### 4.2 仿真分析

通过 GRA 计算各影响因素关联度的分析结果如表 3 所示, 本文挑选关联度高于 0.75 的数据带入预测模型。根据计算结果, 平均温度和平均湿度关联度分别为 0.595 和 0.710 不满足要求, 因此 SVM 的输入分别为飞行时长、起落架次、失效率和人员因素四个影响因素。

表 3 各影响因素关联度分析  
Table 3 Correlation analysis of the influencing factors

影响因素	灰色关联度	影响因素	灰色关联度
$x_1$	0.885	$x_4$	0.595
$x_2$	0.888	$x_5$	0.710
$x_3$	0.759	$x_6$	0.866

分别利用 IPSO 和 PSO 算法对 SVM 的参数进行寻优, 改进前后适应度曲线对比图如图 2 所示。IPSO 算法在 46 次迭代后得出最优的适应度值为 0.004 2, 寻找到最优  $C$  为 8.69、最优  $g$  为 0.14; 而 PSO 算法在第 78 次迭代后得出最优适应度值为 0.005 5, 寻找到最优  $C$  为 5.42、最优  $g$  为 0.30, 由此可见, IPSO 比 PSO 算法能在更短的时间找到最优的解。

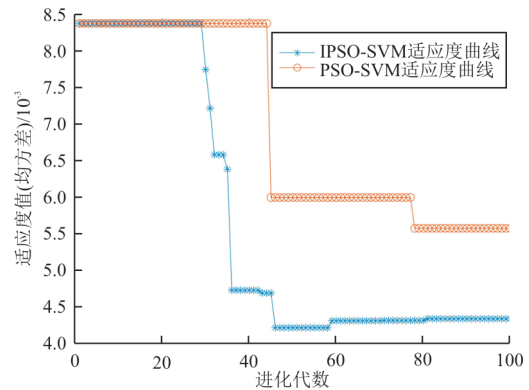


图 2 改进前后适应度曲线对比图

Fig. 2 Comparison of adaptation curves before and after improvement

本文检验预测方法的指标分别为均方根误差  $e_{RMS}$ 、平均绝对百分比误差  $e_{MAP}$  和预测耗时三个指标,  $e_{RMS}$  和  $e_{MAP}$  表达式如下:

$$e_{RMS} = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}} \quad (14)$$

$$e_{MAP} = \left( \frac{100}{n} \right) \sum_{t=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| \quad (15)$$

式中:  $n$  为样本数;  $y_t$  为实际航材需求量;  $\hat{y}_t$  为预测的航材需求量;

基于 PSO-SVM、GRA-PSO-SVM 和 GRA-IPSO-SVM 三种预测方法的性能指标对比如表 4 所示。

表 4 三种预测方法的性能指标对比表  
Table 4 Comparison of performance indicators of the three prediction methods

方法	最优 $C$	最优 $g$	$e_{RMS}$	$e_{MAP}/\%$	耗时/s
GRA-IPSO-SVM	8.69	0.14	0.43	3.43	4.14
GRA-PSO-SVM	5.42	0.30	0.51	3.91	4.47
PSO-SVM	11.85	0.45	0.59	5.61	4.84

将寻找的最优参数和测试集分别带入三种预测方法进行预测, 三种方法的预测结果对比如图 3

所示,可以看出:基于GRA-PSO-SVM的预测方法相对于基于PSO-SVM的预测方法,预测的 $e_{RMS}$ 下降0.08, $e_{MAP}$ 下降1.7%,预测时间减少了0.37 s;而基于GRA-IPSO-SVM的预测方法相对于基于PSO-SVM的预测方法,预测的 $e_{RMS}$ 下降0.16, $e_{MAP}$ 下降2.18%,预测时间减少了0.7 s。

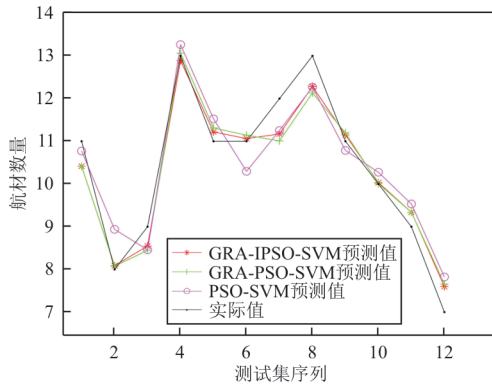


图3 三种方法的预测对比示意图

Fig. 3 Comparison diagram of the predictions of the three methods

## 5 结 论

(1) 通过对比基于GRA-PSO-SVM和基于PSO-SVM方法的预测结果,使用GRA分析航材携行需求因素能避免个别因素的干扰,减少预测时间和提高预测精度。

(2) IPSO算法比PSO算法能在更短的时间寻找到最优的SVM参数。

(3) 采用基于GRA-IPSO-SVM的方法预测航材需求具有精度高、误差小和耗时短的特点,更趋近于实际情况,为航材携行预测需求提供了新的方法。

### 参考文献

[1] 宋传洲,王瑞奇,刘战. 面向任务携行航材消耗影响因素研究[J]. 航空维修与工程, 2020(8): 68-71.  
SONG Chuazhou, WANG Ruiqi, LIU Zhan. Study on the factors influencing the consumption of mission-oriented flight material[J]. Aviation Maintenance and Engineering, 2020 (8): 68-71. (in Chinese)

[2] 李连,孙聪,苏涛. 改进BP网络在航材需求预测中的应用[J]. 计算机与现代化, 2012(8): 179-182,186.  
LI Lian, SUN Cong, SU Tao. Application of improved BP network in aviation material demand forecasting[J]. Com-

puters and Modernization, 2012(8): 179-182,186. (in Chinese)

[3] 程玉波,车建国,杨作宾,等. 基于指数平滑法的装备维修器材需求量预测[J]. 指挥控制与仿真, 2009, 31(1): 115-117.  
CHENG Yubo, CHE Jianguo, YANG Zuobin, et al. Exponential smoothing method based on equipment maintenance equipment demand prediction [J]. Command Control and Simulation, 2009, 31(1): 115-117. (in Chinese)

[4] 王斌,王勤为,董科,等. 基于二次指数平滑预测的虚拟机调度方法研究[J]. 计算机应用研究, 2017, 34(3): 19-22.  
WANG Bin, WANG Qinwei, DONG Ke, et al. Research on virtual machine scheduling method based on quadratic exponential smoothing prediction [J]. Computer Application Research, 2017, 34(3): 19-22. (in Chinese)

[5] 夏贵进,张曦,张居梅,等. 基于三次指数平滑法的光纤损耗预测研究[J]. 光通信技术, 2014, 38(1): 35-37.  
XIA Guijin, ZHANG Xi, ZHANG Jumei, et al. Research on fiber loss prediction based on cubic exponential smoothing method[J]. Optical Communication Technology, 2014, 38 (1): 35-37. (in Chinese)

[6] 毕钊,侯胜利. 基于R语言SARIMA模型的航材需求预测分析[J]. 价值工程, 2019(15): 4-7.  
BI Zhao, HOU Shengli. Forecasting analysis of aviation material demand based on SARIMA model in R language[J]. Value Engineering, 2019(15): 4-7. (in Chinese)

[7] CROSTON J D. Forecasting and stock control for intermittent demands[J]. Journal of the Operational Research Society, 1972, 23(3): 289-303.

[8] TEUNTER R H, SYNTETOS A A, BABAI M Z. Intermittent demand: linking forecasting to inventory obsolescence[J]. European Journal of Operational Research, 2011, 214(3): 606-615.

[9] 尚琦坤,陈云翔. 任务驱动下航材需求量的GA-GM-BP预测[J]. 火力与指挥控制, 2013, 38(4): 78-82.  
SHANG Qikun, CHEN Yunxiang. GA-GM-BP prediction of mission-driven aerial material requirements[J]. Fire Control and Command Control, 2013, 38(4): 78-82. (in Chinese)

[10] 曾浩然,冯蕴雯,路成,等. 基于支持向量机回归的民用飞机航材消耗预测研究[J]. 航空工程进展, 2021, 12(5): 75-79.  
ZENG Haoran, FENG Yunwen, LU Cheng, et al. Research on civil aircraft aerial material consumption prediction based on support vector machine regression[J]. Advances in Aeronautical Science and Engineering, 2021, 12(5): 75-79. (in Chinese)

- [11] 孙绳山, 徐常凯, 何亚群. 基于RS-PSO-SVM的航材消耗预测模型[J]. 南京航空航天大学学报, 2021, 53(6): 881-887.  
SUN Shengshan, XU Changkai, HE Yaqun. RS-PSO-SVM-based prediction model for aerial material consumption [J]. Journal of Nanjing University of Aeronautics and Astronautics, 2021, 53(6): 881-887. (in Chinese)
- [12] 宋传洲, 王瑞奇, 刘天庆, 等. 基于XGBoost-GRA-DEMATEL面向任务携行航材消耗预测方法[J]. 航空兵器, 2021, 28(4): 88-96.  
SONG Chuazhou, WANG Ruiqi, LIU Tianqing, et al. A mission-oriented flight material consumption prediction method based on XGBoost-GRA-DEMATEL [J]. Aviation Weapons, 2021, 28(4): 88-96. (in Chinese)
- [13] 刘英杰, 聂章琴, 王博, 等. 基于 PSO-SVM 的水工隧洞施工成本预测[J]. 人民黄河, 2021, 43(9): 160-164.  
LIU Yingjie, NIE Zhangqin, WANG Bo, et al. Construction cost prediction of hydraulic tunnels based on PSO-SVM [J]. People's Yellow River, 2021, 43(9): 160-164. (in Chinese)
- [14] 林升梁, 刘志. 基于RBF核函数的支持向量机参数选择[J]. 浙江工业大学学报, 2007, 35(2): 163-167.  
LIN Shengliang, LIU Zhi. Parameter selection for support vector machines based on RBF kernel functions [J]. Journal of Zhejiang University of Technology, 2007, 35(2): 163-167. (in Chinese)
- [15] 程云芳, 邱榕. 基于粒子群-支持向量机(PSO-SVM)的苯储罐泄漏事故风险预测[J]. 火灾科学, 2020, 29(3): 190-198.  
CHENG Yunfang, QIU Rong. Particle swarm-support vector machine (PSO-SVM) based risk prediction for benzene storage tank leakage accidents [J]. Fire Science, 2020, 29(3): 190-198. (in Chinese)
- [16] 马钢, 李俊飞, 白瑞, 等. 基于 PSO-SVM 模型的油气管道内腐蚀速率预测[J]. 表面技术, 2019, 48(5): 43-48.  
MA Gang, LI Junfei, BAI Rui, et al. Prediction of corrosion rate inside oil and gas pipelines based on PSO-SVM model [J]. Surface Technology, 2019, 48(5): 43-48. (in Chinese)
- [17] 王二涛, 高惠瑛, 孙海, 等. 基于 PSO-SVM 的城市桥梁群体震害预测模型研究[J]. 震灾防御技术, 2017, 12(1): 185-193.  
WANG Ertao, GAO Huiying, SUN Hai, et al. Research on group seismic damage prediction model of urban bridges based on PSO-SVM [J]. Seismic Defense Technology, 2017, 12(1): 185-193. (in Chinese)

#### 作者简介:

**李黄琪**(1997—),男,硕士研究生。主要研究方向:航材管理,航空发动机故障诊断。

**蔡开龙**(1979—),男,博士,副教授。主要研究方向:航材管理,航空发动机故障诊断,航空发动机控制。

**郝明**(1985—),男,硕士,讲师。主要研究方向:飞机损伤维修与航材备件需求。

**薛红阳**(1997—),男,硕士研究生。主要研究方向:航空发动机控制,航材管理。

**濮志刚**(1997—),男,硕士研究生。主要研究方向:航空发动机建模技术。

**何森**(1996—),男,硕士研究生。主要研究方向:航空发动机故障诊断。

(编辑:丛艳娟)