

基于灰狼算法的民航维修人为差错评价模型

麻鹰,王瑞

(上海大学通信与信息工程学院,上海 200444)

摘要:随着民航运输业的迅猛发展,航空运输量和排班量大幅度增加。航空器在可靠性和安全性等诸多方面都有了大幅度提升。由机械故障导致的安全事故比例从80%下降到了20%,而维修过程中的人为差错占比却直线上升,成为影响民航安全、飞行安全及运行成本的重要因素。因此,民航业对于人为差错备受关注。为了降低民航维修中人为差错的发生几率,提高维修生产和适航质量,该文提出了4个层面、18个影响民航维修人为差错的因子。以东航虹桥基地为例,采用了问卷调查收集数据;通过灰狼算法(grey wolf optimization, GWO)结合粒子群算法(particle swarm optimization, PSO)以及增加三种改进策略,提出一种惯性自适应混合灰狼算法(inertial adaptive hybrid grey wolf optimization, IAHGWO);并构建了惯性自适应混合灰狼算法训练径向基函数神经网络(radial basis function neural network, RBFNN)评价模型;结果表明该评价模型具有良好的实用性及准确性,弥补了现阶段民航企业适航质量监管体系对维修人员个体的人为差错管控中针对性、实时性、预见性上的不足。

关键词:适航质量;人为差错;灰狼算法;径向基函数神经网络;粒子群算法;评价模型

中图分类号: TP183

文献标识码: A

文章编号: 1673-629X(2022)01-0030-05

doi: 10.3969/j.issn.1673-629X.2022.01.006

Human Error Evaluation Model of Civil Aviation Maintenance Based on Gray Wolf Optimization

MA Ying, WANG Rui

(School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China)

Abstract: With the rapid development of civil aviation transportation, the amount of air transportation and scheduling increased greatly. Aircraft have been greatly improved in many aspects, including reliability and safety. The proportion of safety accidents caused by mechanical failures decreased from 80% to 20%, while the proportion of human errors during maintenance increased sharply, becoming an important factor affecting civil aviation safety, flight safety and operation cost. As a result, civil aviation industry is concerned about human error. In order to reduce the probability of human error in civil aviation maintenance and improve maintenance production and airworthiness quality, eighteen factors affecting human error in civil aviation maintenance from four levels are put forward. Taking Hongqiao Base of Eastern Airlines as an example, a questionnaire survey was used to collect data, and an inertial adaptive hybrid gray wolf optimization (IAHGWO) was proposed, which combined with particle swarm optimization (PSO) and three improved strategies, and an evaluation model was constructed to use IAHGWO to train BP neural network. The results show that the proposed evaluation model has great practicability and accuracy, which makes up for the shortcomings of the current airworthiness quality supervision system of civil aviation enterprises in the pertinence, real-time and predictability of human error control of maintenance personnel.

Key words: civil aviation security; human error; grey wolf optimization; radial basis function neural network; particle swarm optimization; evaluation model

0 引言

人为差错是在民航安全中被广泛提及的一个词,它是指人未能按既定计划完成规定任务,从而造成设备、财产损失的行为。

文中设计了一种基于深度学习算法的人为差错评价模型,有助于加强民航企业内部对维修人员的人为差错的管控,降低维修中人为差错的发生率,提高安全生产质量^[1-2]。同时弥补了现阶段民航企业内部对维

收稿日期: 2021-01-27

修回日期: 2021-05-31

基金项目: 国家自然科学基金(61771299)

作者简介: 麻鹰(1988-),男,硕士研究生,研究方向为深度学习、适航质量;王瑞,副教授,硕士,研究方向为信号与信息处理、大数据处理等。

修人员个体人为差错管控上存在的实时性、预测性、针对性的缺陷。

该系统深度学习算法的核心是通过分析人为差错的诱因,构建基于径向基神经网络评价模型;首次提出惯性自适应灰狼算法训练径向基神经网络的权值和阈值,从而使系统具有良好的实用性、准确性。

1 模型构建

1.1 输入层/输出层设计

评价系统的影响因子(输入层)通过研究人为差错的经典文献:SHEL 模型、REASON 模型、墨菲定理、HFACS 系统^[3-5],结合企业业务特点(东航虹桥维修基地为例),以《航空人员的维修差错管理》为基础,提出了各层面:自身层面(M1-M4)、环境层面(N1-N4)、组织层面(X1-X4)、管理层面(Y1-Y6)共计 18 个影响人为差错的因子^[6-7],如表 1 所示。

表 1 影响人为差错的因子

编号	影响因素	编号	影响因素	编号	影响因素
M1	健康状况	N3	航材保障	Y1	组织结构
M2	自信程度	N4	生活保障	Y2	制度规章
M3	工作压力	X1	人际关系	Y3	绩效管理
M4	职业技能	X2	团队协作	Y4	质量监察
N1	工装设备	X3	职责分配	Y5	教育培训
N2	自然环境	X4	人力资源	Y6	企业文化

系统的评价等级(输出层)则主要参考东航《机务维修人员安全积分的管理办法》:安全积分以一个自然年为周期,共计 10 分。发生一般维修差错/严重维修差错/维修事故症候,根据情节的严重程度,扣除安全积分 1 分~3 分/3 分~7 分/7 分~10 分;走访东航虹桥维修基地质量部门 4 名专家,以及大量在岗维修人员,最终确定见表 2:将现有安全积分 3 分(含)以下定义为不安全,即容易发生人为差错;将现有安全积分 7 分(含)以下定义为一般,即可能发生人为差错;将现有安全积分 7 分以上定义为安全,即不容易发生人为差错。

表 2 评价等级与输出层期望值

评价等级	内容	期望值
一级	不易发生人为差错	[1,0,0]
二级	可能发生人为差错	[0,1,0]
三级	容易发生人为差错	[0,0,1]

1.2 算法设计

(1) 径向基神经网络。

径向基函数(radial basis function, RFB)神经网络是由 J. Moody 和 C. Darken 在 80 年代末提出的,它是具有单隐层的三层前馈网络。由于它模拟了人脑中局

部调整、相互覆盖接收域的神经网络结构,有很强的非线性拟合能力,可映射任意复杂的非线性关系,而且学习规则简单,便于计算机实现。具有很强的鲁棒性、记忆能力、非线性映射能力以及强大的自学习能力。因此,RBF 神经网络是一种局部逼近网络,能够以任意精度逼近任意连续函数,特别适合于解决分类问题。

(2) 灰狼算法。

灰狼算法^[8](grey wolf optimization, GWO)是一种基于动物行为学的智能算法。其主要通过模仿狼群的社会关系,以及它们的狩猎、捕猎行为,构建数学模型。狼群共分为 4 个阶层,每个阶层都有严格的阶级分工: α 狼是整个狼群的首领,是最高阶层的狼,对狼群有着绝对的领导能力,狼群中任何狼都必须听命于 α 狼; β 狼是仅次于 α 狼的第二阶层狼,它只听命于 α 狼,并协助领导其余狼; δ 狼再次之,服从 α 狼、 β 狼的领导,且只可以领导普通的 ω 狼。

围猎行为:

$$\begin{cases} \vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \\ \vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \\ \vec{A} = 2a \cdot \vec{r}_2 - a \\ \vec{C} = 2\vec{r}_1 \\ a = 2 - 2(\frac{t}{\max}) \end{cases} \quad (1)$$

其中, \vec{D} 表示个体与食物的距离; t 表示当前迭代的次数; \vec{C} 表示对猎物的扰动; \vec{X}_p 表示目标的位置; \vec{X} 表示当前灰狼个体的位置。在算法的迭代过程中收敛因子 a 从 2 线性递减至 0, \vec{r}_1 、 \vec{r}_2 是 $[0,1]$ 内的随机向量。

狩猎行为:

$$\begin{cases} \vec{D}_\alpha = |C_1 \cdot \vec{X}_\alpha(t) - \vec{X}(t)| \\ \vec{D}_\beta = |C_2 \cdot \vec{X}_\beta(t) - \vec{X}(t)| \\ \vec{D}_\delta = |C_3 \cdot \vec{X}_\delta(t) - \vec{X}(t)| \end{cases} \quad (2)$$

式中: \vec{X}_1 、 \vec{X}_2 、 \vec{X}_3 分别表示当前种群中 α 、 β 、 δ 的位置向量; \vec{X} 表示灰狼的位置向量; \vec{D}_α 、 \vec{D}_β 、 \vec{D}_δ 分别表示当前候选灰狼与最优三条狼之间的距离。当 $|\vec{A}| > 1$ 时,灰狼之间尽量分散在各区域并搜寻猎物;当 $|\vec{A}| < 1$ 时,灰狼将集中搜索某个或某些区域的猎物。

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \end{cases} \quad (3)$$

式(3)分别定义了 ω 狼群中个体朝向 α 、 β 、 δ 前进的步长和方向,式(4)定义了 ω 狼的最终位置。

$$\vec{X}_{(t+1)} = \frac{1}{3}(\vec{X}_1 + \vec{X}_2 + \vec{X}_3) \quad (4)$$

(3) 粒子群算法(PSO)。

粒子群算法^[9](particle swarm optimization, PSO) 是受到鸟群在觅食中迁徙、聚集行为的启发。初始状态下,PSO 是一群随机的粒子,粒子在迭代过程中受到个体极值和全局极值的影响,使粒子向空间内最优解趋近并降落。

核心公式如下:

$$v_i = \omega \cdot v_i + c_1 \cdot r_1(\text{pbest}_i - x_i) + c_2 \cdot r_2(\text{gbest}_i - x_i), x_i = x_i + v_i \quad (5)$$

其中, $i = 1, 2, \dots, N$, N 是粒子总数; v_i 是粒子速度, r_1 、 r_2 是 $[0, 1]$ 的随机数; c_1 、 c_2 学习率为一个常数; ω 是惯性因子,是个非负数。

1.3 算法优化

(1) 社会信息共享机制。

受粒子群算法的启发^[10],根据 ω 狼迭代时的更新位置受到全局最优解 (α 、 β 、 δ 狼) 的影响,建立整个狼群的信息共享交流机制。

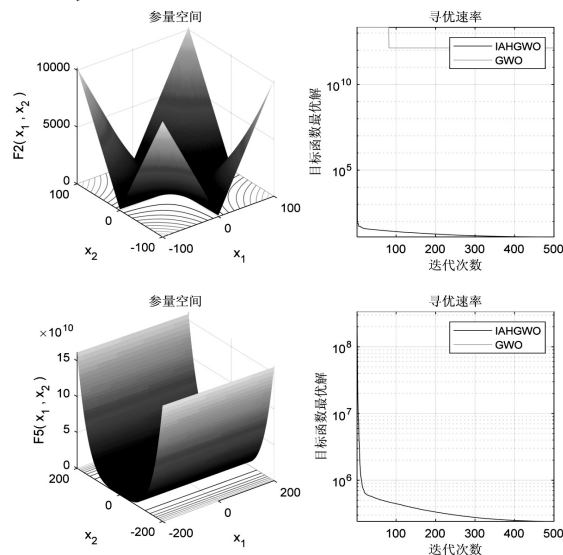
$$v_i^{k+1} = \omega_{i(k+1)} \times [v_i^k + c_1 r_1(x_1 - x_i^k) + c_2 r_2(x_2 - x_i^k) + c_3 r_3(x_3 - x_i^k)]$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (6)$$

(2) 自适应惯性因子策略。

由式(5)得知,惯性因子 ω 直接影响粒子群算法的开发性能。文献[11]中已经证明了 ω 在 $[0.4, 0.9]$ 范围内的自适应变化有效改进了粒子群算法。结合灰狼算法的基本原理^[12-14],提出 ω 狼平均步长 \vec{X} ,将式(4)变换成:

$$\vec{X} = \sum_i \vec{X}_{(t+1)} / i$$



$$\omega_{i(k+1)} = \omega_{\text{start}} \cdot \frac{\omega_{\text{end}}}{\omega_{\text{start}}} \cdot \frac{\vec{X}_k}{|\vec{X}_k - \vec{X}_k|} \cdot \frac{t}{t_{\text{MAX}}} \quad (7)$$

式中, ω_{start} 为 ω 的初始值, ω_{end} 为 ω 的终值, t_{MAX} 为最大迭代数。

(3) 固定扰动 \vec{C} 策略。

标准灰狼算法的 \vec{C} 是狼群对目标的扰动,它是 $[0, 2]$ 的随机值。由于上述策略中引入了若干变量,可能导致系统不稳定。故采用固定 \vec{C} 值的策略来稳定系统寻优。经反复试验 $\vec{C} = 1.9$ 。

综上所述,IAHGWO 算法训练 RBF 神经网络的步骤如图 1 所示。

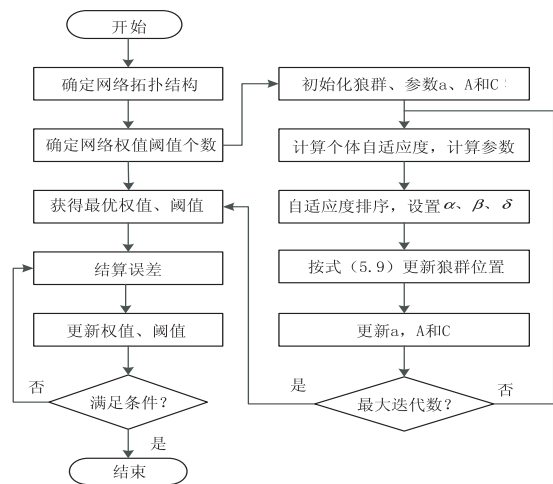


图 1 混合灰狼算法训练 RBF 神经网络流程

1.4 对比仿真

通过 MATLAB2018a 进行仿真对比实验^[15],在灰狼算法原文采用的 23 种基准函数表中分类选取其中具有代表性的基准函数表(见表 3)作对比。设置狼群总数 30;迭代次数 500,取 30 次仿真的平均值,图 2 展示了寻优迭代效率。

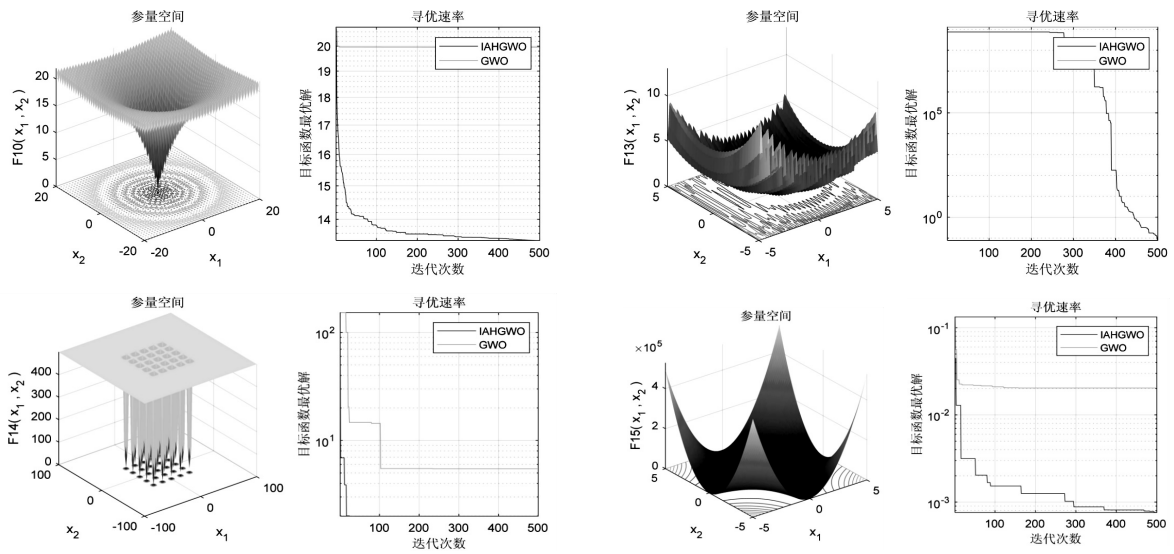


图 2 IAHGWO 与标准 GWO 性能对比

通过比较可以明显看出,文中提出的惯性自适应混合灰狼算法(IAHGWO)在性能上明显优于标准灰狼算法,将惯性自适应混合灰狼算法的适应度函数设为:

$$fitness = \operatorname{argmin} \left[\sum_{i=0}^N (\text{Simout} - \text{GroundTruch})^2 \right]$$




图 3 混合灰狼算法训练 RBF 神经网络误差曲线

优化后的 RBF 神经网络误差值如图 3 所示,呈持续下降的趋势。说明 IAHGWO 对 RBF 神经网络起到了优化作用,使 RBF 神经网络的正确率从 87.65% 提升到了 95.88%。

2 数据采集分析

以东航虹桥维修基地为例,在其内发放问卷 200 份,回收 173 份,其中有效问卷 157 份,有效问卷回收率为 78%。被试者的工作司龄都在 2~20 年间,从事一线维修工作。对采集的数据运用 SPSS22 进行信度和效度分析,结果如表 3、表 4 所示,表明上述问卷采集的数据可以被采纳。

表 3 基准函数参数

表达式	维度	取值范围
$f_2(x) = \sum_{i=1}^D x_i + \prod_{i=1}^D x_i $	30	$x \in [-10, 10]^D$
$f_3(x) = \sum_{i=1}^D \left(\sum_{j=1}^i x_j \right)^2$	30	$x \in [-100, 100]^D$
$f_5(x) = \sum_{i=1}^D [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$x \in [-30, 30]^D$
$f_9(x) = \sum_{i=1}^D [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$x \in [-5.12, 5.12]^D$
$f_{10}(x) = -20\exp(-0.2\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	30	$x \in [-32, 32]^D$
$f_{13}(x) = 0.1 \{ \sin^2(3\pi x_1) + \sum_{i=1}^{D-1} (x_i - 1)^2 [1 + \sin^2(3\pi x_{i+1})] + (x_D - 1)^2 [1 + \sin^2(2\pi x_{i+1})] \} + \sum_{i=1}^D u(x_i, 5, 100, 4)$	30	$x \in [-50, 50]^D$
$f_{14}(x) = \left[\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right]^{-1}$	2	$x_1 \in [-65.56, 65.56]$ $x_2 \in [-65.56, 65.56]$
$f_{15}(x) = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	4	$x_1 \in [-5, 5], x_2 \in [-5, 5]$ $x_3 \in [-5, 5], x_4 \in [-5, 5]$

表 4 信度与效度校验参数

信度			效度		
Cronbach's α	基于标准化项 α	项数	KMO	Bartlett's Sphericity χ^2	Sig
0.795	0.817	18	0.93	2 473.241	0

3 模型应用

使用 MATLAB2018a 将采集的数据代入标准 RBF 神经网络进行训练,结果见图 4。可以看出,RBF 神经网络的误差在第 251 步完成收敛。说明所构建的 RBF 神经网络模型与民航维修中的人为差错,建立了良好的非线性关系。表 5 为东航虹桥维修基地两名一线维修人员的原始数据,通过 IAHGWO-RBF 模型计算,得到与期望值几乎近似的数值,且与两人实际相符,可以

说该模型具有相当强的实用性。




图 4 RBF 神经网络收敛曲线

表 5 原始数据计算结果

	王某原始数据	安全积分	输出值	期望值		叶某原始数据	安全积分	输出值	期望值
M1	9 X2 7				M1	8 X2 6			
M2	8 X3 8		1.00	1	M2	8 X3 7		0.01	0
M3	8 X4 9				M3	6 X4 8			
M4	10 Y1 7				M4	10 Y1 5			
N1	10 Y2 8	9	0.01	0	N1	6 Y2 10	6	0.98	1
N2	6 Y3 10				N2	9 Y3 8			
N3	8 Y4 8				N3	7 Y4 7			
N4	9 Y5 8		0.02	0	N4	4 Y5 6		0.01	0
X1	10 Y6 9				X1	7 Y6 8			

4 结束语

提出一种惯性自适应混合灰狼算法,通过与标准灰狼算法做仿真比较,证明了该算法的优越性。

通过惯性自适应混合灰狼算法训练后 RBF 神经网络,误差显著下降,准确率从 87.65% 提升到了 95.88% 以东航虹桥维修基地为例,验证了构建的民航维修人为差错评价模型具有良好的实用性和准确性。为后期的推广提供了实践基础。

参考文献:

[1] International Civil Aviation Organization. Safety management manual[M]. Beijing: International Civil Aviation Organization, 2013.

[2] Civil Aviation Administration of China. CCAR 396-R3 Safety information regulations of civil aviation[S]. Beijing: Civil Aviation Administration of China, 2016.

[3] 王衍洋,李敬,曹义华. 中国民航安全评价方法研究[J]. 中国安全生产科学技术, 2008, 4(5): 111-113.

[4] 史亚杰,李敬. 民航机务维修系统安全风险监测[J]. 中国安全科学学报, 2009, 19(11): 110-116.

[5] 王洪德,潘科. 基于 BP 神经网络的民航机场安全预警研究[J]. 安全与环境学报, 2008, 8(4): 139-143.

[6] 甘旭升,崔浩林,高文明,等. 基于 HFACS 的空中相撞事故

分析及建议[J]. 中国安全生产科学技术, 2015, 11(10): 96-102.

[7] 花迎春,邹葆华,高文明. 航空维修系统危险源识别和风险分析方法[J]. 中国安全生产科学技术, 2013, 9(3): 104-107.

[8] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

[9] CHAUHAN P, DEEP K, PANT M. Novel inertia weight strategies for particle swarm optimization[J]. Memetic Computing, 2013, 5(3): 229-251.

[10] 李龙澍,张效见. 一种新的自适应惯性权重混沌 PSO 算法[J]. 计算机工程与应用, 2018, 54(9): 139-144.

[11] 张顶学,关治洪,刘新芝,等. 一种动态改变惯性权重的自适应粒子群算法[J]. 控制与决策, 2008, 23(11): 1253-1257.

[12] CHALERMCHAIARBHA S, ONGSAKUL W. Stochastic weight trade-off particle swarm optimization for nonconvex economic dispatch[J]. Energy Conversion and Management, 2013, 70: 66-75.

[13] 杜霖,曹江涛,李书臣. 基于惯性权重矩阵的自适应粒子群算法[J]. 控制工程, 2018, 25(7): 1303-1311.

[14] 郭振洲,刘然,拱长青,等. 基于改进灰狼算法的 RBF 神经网络研究[J]. 微电子学与计算机, 2017, 34(7): 7-10.

[15] 史峰,王小川,郁磊,等. MATLAB 神经网络 30 个经典案例[M]. 北京:北京航空航天大学出版社, 2010.