

基于多策略协同优化神经网络的起落架状态监测

冯蕴雯¹, 王锐¹, 卢涛², 陈俊宇¹, 路成¹

(1.西北工业大学 航空学院, 陕西 西安 710072; 2.中国航天北京宇航系统工程研究所, 北京 100076)

摘要: 为了有效监测飞机着陆阶段起落架运行状态, 提出一种基于多策略协同优化的反向传播神经网络算法 (back propagation neural network-based on multi-strategy cooperative optimization, MSCO-BPNN)。多策略优化算法由混沌映射策略、自适应螺旋捕获策略、交叉变异策略及鲸鱼优化算法 (whale optimization algorithm, WOA) 组成, 其中 WOA 旨在捕获神经网络的最优超参数值, 混沌映射策略、自适应螺旋捕获策略及交叉变异策略分别用于提升鲸鱼优化算法在寻优过程中的搜索效率、多局部搜索能力及全局最优搜索性能。具备最优超参数的 BP 神经网络用于建立输入参数与输出响应间的隐式模型。以机载快速存储记录 (quick access recorder, QAR) 数据中起落架左侧刹车温度运行状态为对象进行健康监测, 通过对比 WOA-BPNN、粒子群优化 BPNN、传统 BPNN 与所提 MSCO-BPNN 算法, 分别验证所提算法在起落架运行状态监测建模方面的有效性和适用性。结果表明 MSCO-BPNN 能够以高效率和高精度进行起落架运行状态监测, 可推广至复杂系统的运行健康监控领域。

关键词: 起落架; 鲸鱼优化算法; 机载快速存储数据; 状态监测; 反向传播神经网络
中图分类号: V267 **文献标志码:** A **文章编号:** 1000-2758(2023)02-0264-10

起落架在着陆阶段的工作状况与乘客的人身安全联系紧密, 刹车温度作为其中重要影响因素之一, 其异常运行状态的发生可能会使运行性能大幅退化, 导致危险事故发生。为保障飞机正常运行及乘客生命安全, 有必要对起落架运行状态进行监测^[1-3]。

运行状态监测是指通过连续对机器或设备进行监测, 从而预测设备可能在何时产生参数波动导致结构出现失效。对飞机起落架进行状态监测, 有助于实时了解起落架的健康状况, 从而制定维修或保养依据, 减少不必要的维修。现有运行状态基础数据包含失效数据、实验退化数据、振动信号数据及类似设备历史运行数据等, 可作为监测基础数据对运行状态进行识别。但其识别仅限于定性描述, 未涉及定量的实时状态测评^[4-7]。近年来, 随着传感器技术、数据采集技术和数据传输技术的发展, 机载快速存储记录 (quick access recorder, QAR) 数据的产生, 为起落架系统的定量状态评估创造了条件。

QAR 所记录数据包含起落架在内多系统的飞机运行参数, 数据范围广泛且信息量充分, 可作为起落架系统运行状态定量监测的数据源, 以提升运行状态监测的有效性^[8-10]。

运行状态监测常用方法有基于统计分析的方法^[11-13]、基于状态外推的方法^[14-15]、基于相似性的方法^[16-18]等, 上述方法都是基于已有的历史数据以及相似设备的数据开展状态监测, 但对于起落架系统这类运行状态波动较大的设备缺乏精准监测能力。反向传播神经网络 (back propagation neural network, BPNN) 作为一种智能学习算法, 相较于其他的传统机器学习算法, 具有高泛化性、高精度、强鲁棒性, 被广泛应用于数据挖掘和模式识别, 在航空领域得到了很好的应用^[18-21]。由于 BPNN 的非线性性质, 超参数的取值极大地影响了该算法的效率与精度^[22]。超参数设置不合理容易导致神经网络陷入局部最优, 因此有必要开展超参数优化以改进 BPNN。

收稿日期: 2022-07-02

基金项目: 国家自然科学基金 (51875465) 资助

作者简介: 冯蕴雯 (1968—), 西北工业大学教授, 主要从事飞行器可靠性分析及运行维护研究。

e-mail: fengyunwen@nwpu.edu.cn

群智能优化算法作为超参数寻优的必要途径之一,通过个体间的协作与竞争,实现复杂空间最优解的搜索。崔建国等^[23]以实验所获取的飞机刹车系统刹车片累积磨损量为参数数据,运用 BPNN 和粒子群优化灰色预测模型对飞机刹车片累积磨损量进行了预测。李耀华等^[24]采用熵权人工蜂群算法 (artificial bee algorithm, ABC) 优化 BPNN 神经网络的故障诊断模型。谷润平等^[25]结合主成分分析 (principal component analysis, PCA) 以及遗传算法 (genetic algorithm, GA) 优化 BPNN 方法实现了飞机落地剩油预测。徐怡等^[26]构建 PCA-GA-BPNN 组合预报模型对民航事故征率进行预测,并建立民航风险评价体系。上述算法以多种寻优角度对 BPNN 超参数展开了优化,但仍存在易陷入局部最优的问题,因此在复杂问题中搜索全局最优解的能力有待提高。为捕获 BPNN 的最优超参数,有必要引入优化策略提高优化算法全局搜索的能力,以提高传统 BP 的计算效率与计算精度。

为实现起落架运行状态监测,本文引入多种优

化策略以及鲸鱼优化算法 (whale optimization algorithm, WOA) 优化 BPNN 的超参数,提出多策略协同优化神经网络算法 (back propagation neural network-based on multi-strategy cooperative optimization, MSCO-BPNN), 以建立飞机运行参数与起落架状态参数间的高关联度模型,实现对飞机着陆过程刹车温度的快速反馈,达到监测起落架运行状态的作用。并使用 QAR 数据进行飞机起落架左侧刹车温度的运行状态监测,以验证所提出方法模型的有效性。

1 起落架运行状态监测模型

对飞机起落架进行状态监测,有助于诊断起落架的健康状况。QAR 数据作为一种具有高时效性的飞机运行数据,包含了飞机飞行姿态、环境参数、飞行速度在内的大量飞机运行状态信息。基于 QAR 数据这一基础数据集,通过建立 MSCO-BPNN 模型进行运行状态监测,基本流程如图 1 所示。

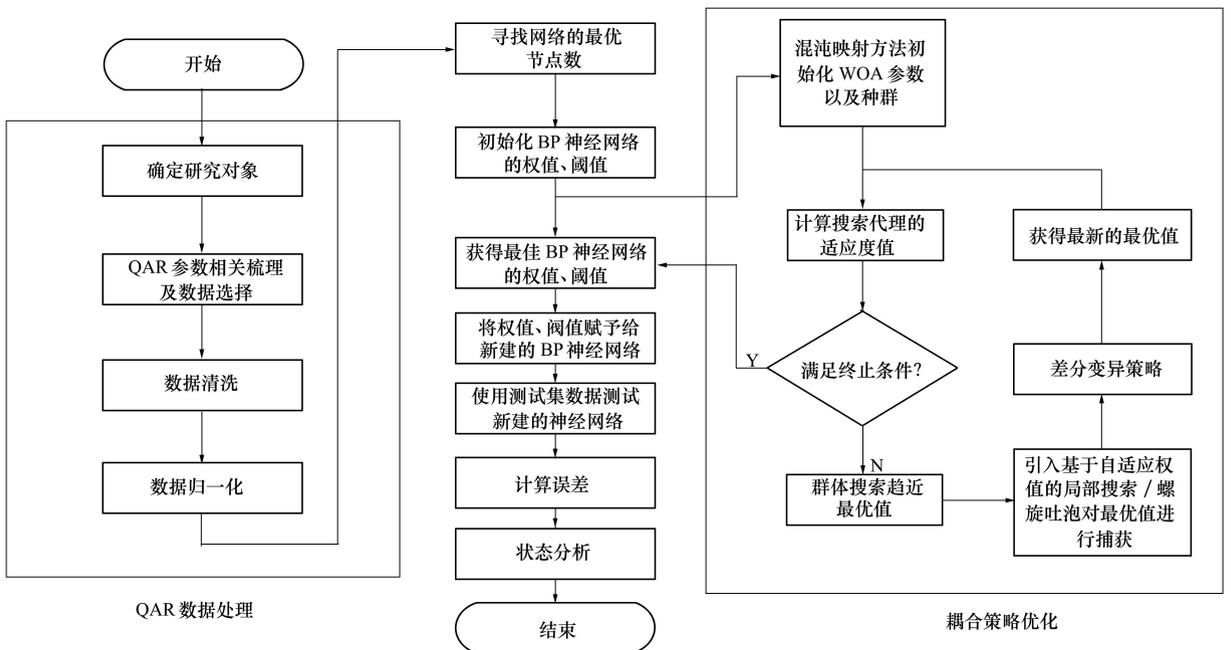


图 1 起落架运行状态评估流程图

1) 以某型民用飞机起落架 QAR 数据作为基础数据集,明确预测对象,结合皮尔逊相关性系数筛选输入参数及输出响应,形成包含训练样本和测试样本的模型样本集;

2) 以训练样本建立 BPNN 初始网络,将其平均

绝对误差作为模型优劣程度评价指标,寻找最优隐藏神经元个数,定义各层节点个数;

3) 采用混沌映射策略初始化超参数种群,引入自适应螺旋捕获策略及交叉变异策略,建立具有最优超参数的 MSCO-BPNN 监测模型,并以测试样本

检验该模型的有效性。

2 多策略协同优化 BP 算法

2.1 BPNN 超参数影响分析

BP 神经网络通过广义感知机以训练误差迭代更新超参数实现反向传播过程,如图 2 所示。

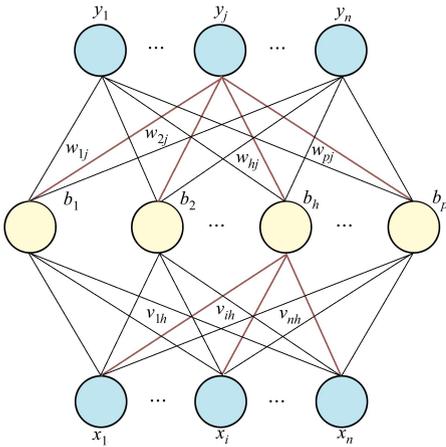


图 2 BP 神经网络参数传播

基于梯度下降理论^[27]及均方误差公式,当给定学习率 η 时,权重 w_{ij} 更新如(1)式所示。

$$\Delta w_{hj} = -\eta \frac{\partial E_n}{\partial w_{hj}} = -\eta \frac{\partial E_n}{\partial \hat{y}_j^n} \cdot \frac{\partial \hat{y}_j^n}{\partial \beta_j} \cdot \frac{\partial \beta_j}{\partial w_{hj}} \quad (1)$$

$$\Delta w_{hj} = \eta \frac{\partial E_n}{\partial \hat{y}_j^n} \cdot \frac{\partial \hat{y}_j^n}{\partial \beta_j} b_h$$

式中: $E_n = \frac{1}{2} \sum_{j=1}^n (\hat{y}_j^n - y_j^n)$ 为网络均方误差; y_j^n 为 n

个输出响应中第 j 个输出响应; $\alpha_j = \sum_{i=1}^p v_{ih}$ 为隐层神经元接收到输入参数; v_{ij} 为第 i 个输入变量 x_i 与第 h 个神经元 b_h 之间的连接权重; p 为隐层神经元个数; $\beta_j = \sum_{h=1}^p \omega_{hj} b_h$ 为输出层第 j 个神经元接收到的输入, \hat{y}_j^n 为训练集模型输出响应, n 为输出响应个数。

阈值 γ 更新公式为

$$\Delta \gamma_h = -\eta \frac{\partial E_n}{\partial \gamma_h} = -\eta \sum_{j=1}^p \frac{\partial E_n}{\partial \beta_j} \frac{\partial \beta_j}{\partial b_h} \cdot \frac{\partial b_h}{\partial \gamma_h} \quad (2)$$

基于超参数权重 w 、阈值 γ 的更新原理,采用输入层、中间层、输出层神经元数量为 3 : 2 : 1 的 BPNN 结构,分析超参数过大、过小以及正常的 3 种情况对 BPNN 输出响应值的结果影响。以同一损失函数计算结果作为衡量标准,损失函数计算值越小即拟合精度越高。超参数取值对 BPNN 拟合精度的影响如图 3 所示。

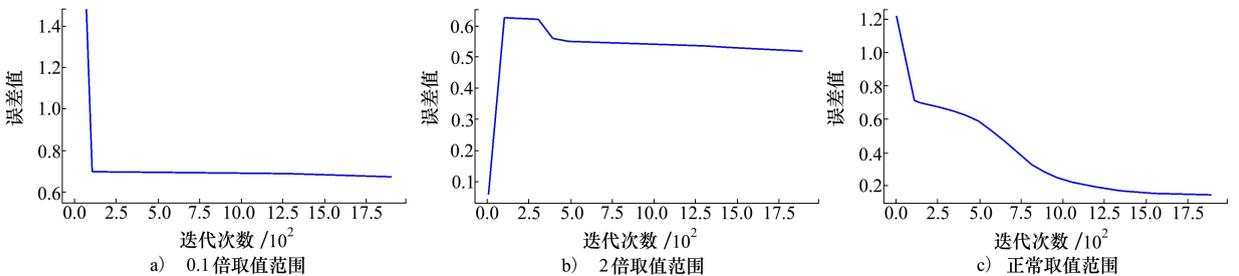


图 3 不同初始超参数的 BPNN 损失函数

由图 3 可得,随着迭代次数的增加,以上 3 种取值情况皆出现收敛趋势。当超参数取值为正常范围时,该模型的收敛速率随迭代次数变化而波动,最终拟合精度达到较高值。当超参数取值为正常范围的 0.1 倍和 2 倍时,其模型收敛速率快速下降,拟合精度较低,未能在迭代终止时取得预期值。上述表征出现的原因在于取值不合理的超参数会使迭代过程中梯度下降速率减慢,导致超参数更新幅度过小。此外,在 BPNN 结构复杂的情况下,模型非线性增加,超参数设置不合理可能会导致超参数在非最优值更新梯度减小为 0,使得超参数不再变化,从而导

致模型陷入局部最优。这说明超参数的取值影响了模型的收敛效率和拟合精度。

为获取 BP 神经网络的最优超参数,提高网络性能,提出多策略协同优化算法(multi-strategy cooperative optimization, MSCO)。该算法由一个基本优化算法 WOA 和多种优化策略构成,相对于其他群优化算法, MSCO-BPNN 结构简单且具有良好的搜索性能。WOA 算法通过模拟座头鲸的捕食行为,分别采用收缩包围机制及螺旋吐泡机制以更高的精度逼近猎物,即最优值点。并引入了座头鲸随机游动

捕食行为完成搜索区域的精确化,其过程如图 4 所示^[27]。WOA 具有良好的搜索性能但仍存在收敛速度等问题,因此引入多种优化策略对 WOA 进行协同优化。

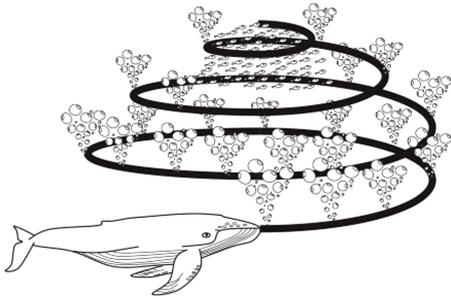


图 4 座头鲸捕食过程

2.2 混沌映射

WOA 通过随机初始化产出初始种群,导致其多样性较弱。为了避免 WOA 因初始种群质量不佳引起的搜索性能下降,引入具有较好遍历均匀性及更快迭代速度的 Tent 混沌映射方法对鲸鱼优化算法初始种群进行改进。基于 Tent 混沌映射的初始化种群原理为

$$y_{k+1}^i = \begin{cases} 2y_k^i, & y_k^i < 0.5 \\ 2(1 - y_k^i), & y_k^i \geq 0.5 \end{cases} \quad (3)$$

$$x_j^i = y_j^i(B_{upper} - B_{lower}) + B_{lower} \quad (4)$$

式中: y_k^i 为 $(0,1)$ 之间的混沌数; B_{upper} 为初始种群上界; B_{lower} 为初始种群下界。

WOA 算法寻优过程分为搜索、包围及狩猎最优值 3 个部分,即首先随机给定个体位置,寻找更接近最优点的个体,再采用螺旋捕获的方式使个体逼近最优值点。采用基于 Tent 混沌映射的 WOA 对最优值点进行搜索和逼近,其数学模型为:

$$\begin{aligned} D &= |CX_{rand} - X(t)| \\ X(t+1) &= X_{rand} - AD \\ D &= |CX^*(t) - X(t)| \\ X(t+1) &= X^*(t) - AD \end{aligned} \quad (5)$$

式中: t 为当前迭代次数; X_{rand} 为随机生成的个体位置; A 和 C 为系数; $X^*(t)$ 为目前为止最好的种群个体的位置向量。 $X(t)$ 为此次迭代种群个体位置, A 和 C 由(6)式得到

$$\begin{aligned} A &= 2ar_1 - a \\ C &= 2r_2 \\ |a| &= 2 - \frac{2t}{T_{max}} \end{aligned} \quad (6)$$

式中: r_1 和 r_2 是 $(0,1)$ 之间的随机数, a 的值从 $2 \sim 0$ 呈线性下降; T_{max} 表示最大迭代次数。

2.3 自适应螺旋捕获策略

座头鲸包围猎物后呈螺旋轨迹游向猎物,故其狩猎行为的数学模型可以用螺旋线表示为

$$X(t+1) = X^*(t) + D_p e^{bl} \cos(2\pi l) \quad (7)$$

式中: $D_p = |X^*(t) - X(t)|$ 表示当前种群个体位置 and 最优取值之间的距离; b 为一个用于定义螺旋轨迹形状的常数; l 是 $(-1,1)$ 之间的随机数。此外, WOA 方法逼近最优取值的同时会进行包围圈的收缩。因此,在同步模型中,假定由某一确定概率 P_i 决定鲸鱼选择螺旋模型或是收缩包围机制来更新当前种群个体的位置。该种随机决策机制的数学模型为

$$X(t+1) = \begin{cases} X^*(t) - AD, & P < P_i \\ X^*(t) + D_p e^{bl} \cos(2\pi l), & P \geq P_i \end{cases} \quad (8)$$

当座头鲸进行攻击猎物行为时,随着 a 值的下降, A 的波动范围也逐渐减小,实现了种群个体向最优值点螺旋靠近的行为。为了使算法具有更好的全局搜索能力,在保持种群多样性的同时能够避免陷入早熟收敛提高局部搜索能力,引入了如(9)式所示的自适应权重。

$$w = 1 - \left[\sin\left(0.5 \frac{t}{T_{max}} \pi\right) \right]^k \quad (9)$$

式中: w 是自适应权重; k 为 $[0,1]$ 之间的经验系数。

为验证 k 取值对算法性能的影响, k 值在 $[0.1, 1]$ 区间中等距取 10 个值,分别代入(9)式得到曲线,如图 5 所示。

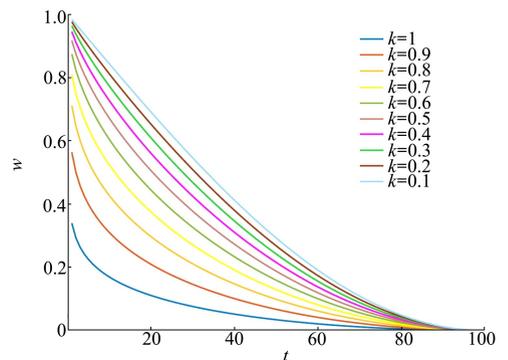


图 5 k 取值对权重的影响

根据 WOA 的搜索原理,权重 w 越大,算法前期

包围曲线的斜率越大,代表算法逼近最优点越迅速,但过快的逼近速度可能导致其跳过最优点,使误差增大。权重 w 越小,包围曲线的斜率越小,代表算法逼近最优点的速度较慢,但同时其搜索的精度得到了提升。采用训练集均方根误差 (root-mean-square error, RMSE) 作为确定 k 值的指标,当 $k=0.4$ 时误差最小,此时 RMSE 为 0.263。

将自适应权重引入鲸鱼优化算法的螺旋模型以及收缩包围机制中,自适应螺旋捕获策略的 WOA 改进算法如下所示

$$X(t+1) = \begin{cases} wX^*(t) - AD, & P < P_i \\ wX^*(t) + D_p e^{bl} \cos(2\pi l), & P \geq P_i \end{cases} \quad (10)$$

2.4 差分变异策略

为确保种群多样性,提升算法的全局寻优性能,引入随机差分变异策略,可得

$$X(t+1) = r_1 \times (X_{best}(t) - X(t)) + r_2 \times (X_r(t) - X(t)) \quad (11)$$

式中: r_1 为 $[0,1]$ 之间的随机数; $|r_2| = 1 - |r_1|$, $X_r(t)$ 为随机鲸鱼个体。 X_{best} 为当前最好的鲸鱼个体位置。

由于 BPNN 的高非线性以及预测输入参数的强耦合性,其权重和阈值的最佳初值往往难以获取。MSCO-BPNN 能够准确迅速逼近最优值点的特性,有助于确定 BPNN 神经元的最佳权值、阈值,从而提升 BPNN 预测精度,且由于不需反复在全局进行搜索, MSCO-BPNN 算法有着更快的收敛速度,弥补了 BPNN 在收敛速度方面的不足。

3 案例分析

由于飞机起落架在整个飞行任务阶段除起飞、降落阶段外其他飞行阶段几乎不工作,且飞机在降落过程中起落架性能波动更大,本文仅考虑飞机起落架在着陆阶段存储的 QAR 数据。通过飞机起落架运行原理结合相关系数进行筛选,提取包括影响飞机着陆姿态、飞机着陆载荷以及飞机起落架运行状态的特征 QAR 数据,若某行特征值缺失,则使用线性插值方法对缺失值进行填充,确保数据的合理性。选择左侧刹车温度作为监测模型输出响应,并筛选确定与刹车温度相关性较高的参数作为监测模型输入变量。

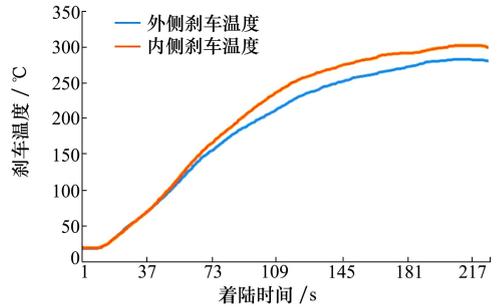


图 6 左侧刹车温度曲线

由图 6 知,起落架刹车温度在一次着陆过程中会从室温上升至几百摄氏度,刹车温度的异常对起落架运行状态有较大影响,若刹车温度过高则会导致刹车片材料力学性能和表面摩擦性能退化,起落架系统着陆滑行距离增加。这一现象的产生可能会导致飞机冲出跑道,对乘客的人身安全造成威胁。因此,为明确起落架的运行状态,将左侧刹车温度作为起落架状态监测对象。

3.1 QAR 数据筛选

为准确监测起落架运行状态,采用皮尔逊相关系数对输入参数进行筛选,以得到与左侧刹车温度高相关性的输入参数。皮尔逊相关系数原理如 (12) 式所示

$$P_{XY} = \frac{\text{cov}(X, Y)}{S_X S_Y} \quad (12)$$

式中: $\text{cov}(X, Y)$ 为输入输出参数样本协方差; S_X, S_Y 为输入输出参数样本方差。

为预测起落架左侧刹车温度,需根据飞机着陆刹车过程中起落架刹车的工作机理筛选相关影响参数。影响起落架左侧刹车温度的运行因素筛选原则如下:

- 1) 在飞机着陆刹车过程中机轮刹车系统受到外界环境影响如地面温度、湿度、风速和风向等。
- 2) 在着陆刹车过程中,飞行员常开启发动机反推并开启扰流板进行减速,因此需要提取发动机系统和飞行控制系统与发动机反推和扰流板角度等相关参数。
- 3) 对刹车系统而言,机轮刹车温度还与飞行员操纵刹车踏板、刹车压力有关。
- 4) 针对机轮刹车温度,时间因素及飞机姿态相关参数可能会造成一定的影响。其中飞机姿态相关参数应包含俯仰、偏航和滚转等。这主要是由于不同的飞机姿态可能导致刹车温度出现变化。

基于上述分析,采用线性插值方法填充 QAR 数

据缺失部分,并归一化处理多组传感器实测数据,进而得到与左刹车温度相关性较高的输入参数。采用皮尔逊相关系数进行相关性分析,量化刹车温度因素影响程度,选择皮尔逊相关系数较大者作为输入变量。经过处理后的输入变量如表 1 所示。

表 1 与机轮刹车温度相关的参数

参数	使用记录格式	数据类型	数据
BRAKE PRESSURE LEFT	刹车压力左	PSI	连续量
LEFT WHEEL SPEED	轮速左	Kts	连续量
BRAKE TEMPERATURE LEFT	左侧刹车温度	Deg	连续量
ENG1 N1	发动机 1N1	%RPM	连续量
ENG2 N1	发动机 2N1	%RPM	连续量
TRAS LVDT LT	反推作动系统位置左	无	连续量
TRAS LVDT RT	反推作动系统位置右	无	连续量
SPOILER ANGLE LEFT	左扰流板角度	DEG	连续量
SPOILER ANGLE RIGHT	右扰流板角度	DEG	连续量
ROLL ANGLE	滚转角	DEG	连续量
MACH	马赫数	Mach	连续量
LONGITUDINAL ACCELERATION	纵向加速度	G	连续量
WIND DIRECTION	风向	DEG	连续量
WIND SPEED	风速	Kts	连续量
LATERAL ACCELERATION	横向加速度	G	连续量
VERTICAL ACCELERATION	垂直加速度	G	连续量

3.2 基于 MSCO-BPNN 的起落架左侧刹车温度运行状态监控模型

3.2.1 模型建立

基于执行连续 6 次飞行任务的航班 QAR 数据,将前 5 个航班数据用作建立 MSCO-BPNN 的训练样本,最后的一次航班数据作为模型验证的测试样本。

根据如表 1 所示的输入参数和左侧刹车温度这一输出响应,确定神经网络的输入层输出层神经元

个数分别为 16 和 1。如表 2 所示,训练集的最小均方误差(mean square error, MSE)大小为 2.92×10^{-5} ,此时节点数为 13。

表 2 不同隐含节点数的训练集误差

隐含节点数	训练集均方误差	隐含节点数	训练集均方误差
5	4.58×10^{-4}	10	3.62×10^{-5}
6	6.72×10^{-4}	11	3.06×10^{-4}
7	2.85×10^{-4}	12	5.17×10^{-5}
8	4.19×10^{-4}	13	2.92×10^{-5}
9	1.01×10^{-4}	14	3.05×10^{-5}

选择 MSCO-BPNN 结构为“16-13-1”3 层网络结构。如(13)式所示,输入层到隐含层、隐含层到输出层的传递函数分别为“tansig”及“purelin”,传递函数表达式为:

$$y_{\text{tansig}} = \frac{2}{1 + e^{-2x}} - 1 \quad (13)$$

$$y_{\text{purelin}} = x$$

式中: y_{tansig} 为输入层到隐含层传递函数; y_{purelin} 为隐含层到输出层的传递函数。

取初始种群数为 $N = 50$,测试集的 MSE 作为适应度,经过 100 次迭代后种群适应度变化如图 7 所示。适应度值越小,表明模型的预测精度越高。

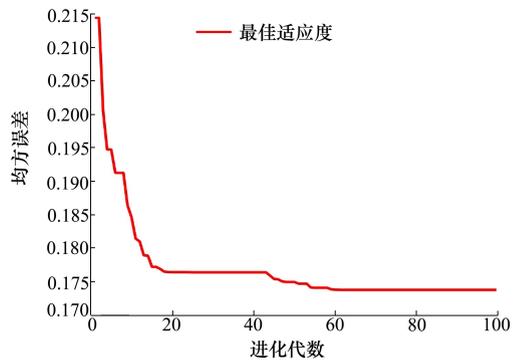


图 7 种群适应度进化曲线

将经过 MSCO 后的权值阈值赋值给 BPNN 模型,从而得到基于 MSCO-BPNN 的起落架运行状态监测模型。优化后的神经网络权值 w_{BP} 及阈值 γ 如(14)式及(15)式所示

$$w_{BP} = \begin{pmatrix} 0.81 & 0.20 & \cdots & 0.68 \\ 0.66 & 3 & \cdots & 3 \\ \vdots & \vdots & & -3 \\ 0.98 & 3 & \cdots & 1.35 \end{pmatrix}_{13 \times 16} \quad (14)$$

$$\gamma = [-197 \quad 2.42 \quad \cdots \quad 0.89]_{1 \times 13} \quad (15)$$

3.2.2 基于 MSCO-BPNN 的起落架左侧刹车温度分析

基于训练集数据,采用 MSCO-BPNN 对着陆阶段的左侧刹车温度进行运行状态监测,结果如图 8

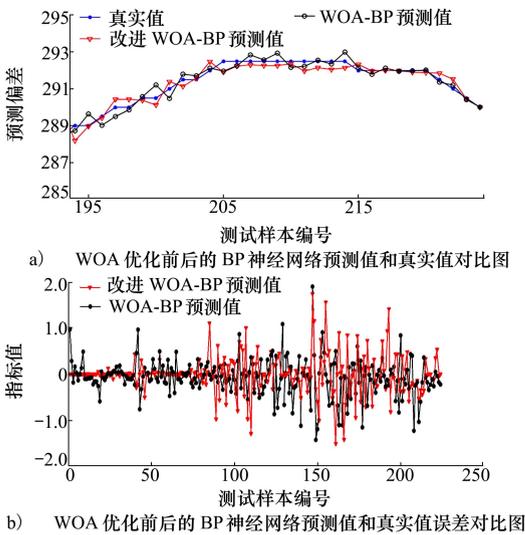


图 8 起落架运行温度预测

表 3 MSCO-BPNN、WOA-BPNN、PSO-BPNN 和传统 BPNN 方法误差对比

误差类型	分析误差				较 BPNN 分析误差降低百分比/%		
	BPNN	MSCO-BPNN	WOA-BPNN	PSO-BPNN	MSCO-BPNN	WOA-BPNN	PSO-BPNN
MAE	1.024	0.235	0.287	0.305	77.1	71.9	70.1
MSE	2.059	0.126	0.173	0.236	93.9	91.5	88.5
RMSE	1.435	0.360	0.417	0.486	74.9	70.9	66.1
MAPE	6.34×10^{-3}	1.21×10^{-3}	1.33×10^{-3}	1.64×10^{-3}	80.9	79.1	74.1

由表 3 可以看出,所提出的 MSCO-BPNN 方法分析精度在 4 种误差指标分析条件下均为 3 种群优化算法最优者,分别为 0.235, 0.126, 0.360, 1.21×10^{-3} 。WOA-BPNN 的分析精度次之,4 种误差指标分别为 0.287, 0.173, 0.417, 1.33×10^{-3} , PSO-BPNN 精度最低,4 种误差指标分别为 0.305, 0.236, 0.486, 1.64×10^{-3} 。因此, MSCO-BPNN 方法精度优于另外 3 种基于数据的状态监测分析方法,原因在于自适应螺旋捕获策略和交叉变异策略分别提高了算法对于 BPNN 超参数的局部最优搜索能力以及全局最优搜索能力,从而提升了 BPNN 的监测精度。

所示。与真实值相比, MSCO-BPNN 分析值整体趋势相近且与真实值的 MSE 为 0.125 6, 分析误差为工程应用所能接受的范围内。

4 对比验证

本节以监测效率和监测精度为验证依据,以 BPNN、粒子群优化 (particle swarm optimization, PSO) BPNN, WOA-BPNN 作为比较对象,验证所提出的 MSCO-BPNN 运行状态监测的有效性和适用性。

4.1 算法精度分析

基于飞机降落阶 QAR 数据中测试集样本,为了从多个角度评价刹车温度分析的准确性,引入平均绝对误差 (mean absolute error, MAE)、MSE、RMSE、平均绝对百分比误差 (mean absolute percentage error, MAPE) 4 种评价指标对不同的刹车温度分析算法进行评价,其中, MAE 可以反映预测值误差的实际情况, MSE 用以监测模型输出值与真实值的偏差, RMSE 在 MSE 的基础上作平方根来观测输出值的偏差, MAPE 从误差相对大小的角度对误差加以表征。

4.2 算法效率分析

将模型运用于 100~100 000 个输入样本数的状态分析过程,并以 BPNN 运行时间作为比较基准。由表 4 可以看出,在模型建模效率方面, MSCO-BPNN 运行效率提升趋势均为先增后减,降低的原因为样本量太大导致计算机运行速率饱和,从而使得上述算法运行速率降低。此外,由运算效率提升百分比可知, MSCO-BPNN 在 4 种样本数量的条件下模拟效率均明显高于其他 2 种群优化算法。当样本数量为 10 000 时, MSCO-BPNN 模拟时间仅为 0.363 s, WOA-PSO 次之。 MSCO-BPNN 具有较高计

算效率的原因在于 Tent 映射优化了初始种群的多 样性,使算法更快收敛,从而提高算法的监测效率。

表4 MSCO-BPNN、WOA-BPNN、PSO-BPNN 和传统 BPNN 方法运行时间对比

输入样本 个数	算法运行时间/s				较 BPNN 算法效率提升百分比/%		
	BPNN	MSCO-BPNN	WOA-BPNN	PSO-BPNN	MSCO-BPNN	WOA-BPNN	PSO-BPNN
100	0.281	0.162	0.225	0.187	42.3	19.9	33.5
1 000	0.462	0.201	0.307	0.285	56.5	33.6	38.3
10 000	0.927	0.363	0.437	0.401	60.8	52.8	56.7
100 000	2.747	1.623	2.284	2.097	40.9	16.8	23.6

上述分析表明,所提出的 MSCO-BPNN 模型具有良好的运行效率和监测精度,可以实现起落架运行状态监测。

5 结 论

本文提出了一种基于 MSCO-BPNN 的起落架状态监测方法,以提高运行状态监测的精度和效率。在此方法中,应用混沌映射方法处理 WOA 优化算法的初始种群,保证种群的多样性,提高了 WOA 算法优化 BPNN 超参数的收敛速度;采用自适应螺旋捕获策略和交叉变异策略,分别提高 WOA 算法的局部最优点搜索能力以及全局寻优能力,以捕获 BPNN 的最优超参数,从而实现 BPNN 的高效、准确运行状态监测。针对所提出的方法,结合飞机实际降落过程中的 QAR 数据进行了起落架左侧刹车温

度监测,通过对比 WOA-BPNN、PSO-BPNN、BPNN 验证了该方法的性能。主要结论如下:

1) 对 BPNN 影响较大的超参数为权重 w 、阈值 γ ,权重和阈值的初值取值过大或过小均会导致算法迭代效率过慢,甚至有可能使算法陷入局部最优。

2) 所提出的 MSCO-BPNN 模型对左侧刹车温度分析误差位于工程实际所能接受的范围内,在 MAE、MSE、RMSE、MAPE 4 种误差指标下与其他的群优化算法相比,MSCO-BPNN 模型均具有更高的分析精度。

3) 与其他群优化算法相比,MSCO-BPNN 在分析效率方面具有优势。在 100~100 000 个输入样本的情况下算法分析效率均高于 WOA-BPNN 和 PSO-BPNN 模型。这表明 MSCO-BPNN 在起落架刹车温度分析工程问题中具有较高的效率。

参考文献:

- [1] KRÜGER W, BESSELINK I, COWLING D, et al. Aircraft landing gear dynamics: simulation and control[J]. Vehicle System Dynamics, 1997, 28(2/3): 119-158
- [2] 冯蕴雯,朱铮铮,姚雄华,等. 民机起落架安全性分析方法研究[J]. 西北工业大学学报, 2016, 34(6): 969-975
FENG Yunwen, ZHU Zhengzheng, YAO Xionghua, et al. Research on safety analysis method of civil aircraft landing gear[J]. Journal of Northwestern Polytechnical University, 2016, 34(6): 969-975 (in Chinese)
- [3] 薛晶,李玉忍,田广来,等. 飞机刹车盘温度场的有限元分析[J]. 计算机仿真, 2009, 26(4): 27-30
XUE Jing, LI Yuren, TIAN Guanglai, et al. Finite element analysis of temperature field of aircraft brake disc[J]. Computer Simulation, 2009, 26(4): 27-30 (in Chinese)
- [4] 杨全伟,何发东,汪文君,等. 飞机起落架载荷测量中的线性变换与鲁棒性[J]. 应用力学学报, 2013, 30(4): 608-612
YANG Quanwei, HE Fadong, WANG Wenjun, et al. Linear transformation and robustness in load measurement of aircraft landing gear[J]. Chinese Journal of Applied Mechanics, 2013, 30(4): 608-612 (in Chinese)
- [5] SARTOR P, BECKER W, WORDEN K, et al. Bayesian sensitivity analysis of flight parameters in a hard-landing analysis process[J]. Journal of aircraft, 2016, 53(5): 1317-1331
- [6] 祁明亮,邵雪焱,池宏. QAR 超限事件飞行操作风险诊断方法[J]. 北京航空航天大学学报, 2011, 37(10): 1207-1210
QI Mingliang, SHAO Xueyan, CHI Hong. Flight operation risk diagnosis method of QAR overrun event[J]. Journal of Beijing University of Aeronautics and Astronautics, 2011, 37(10): 1207-1210 (in Chinese)

- [7] CHEN J, CHEN S, LIU Z, et al. Health monitoring of landing gear retraction/extension system based on optimized fuzzy C-means algorithm[J]. *IEEE Access*, 2020, 8: 219611-219621
- [8] SARTOR P, SCHMIDT R K. Aircraft landing gear structural health monitoring using a loads monitoring approach[J]. *Revue Internationale de la Croix-Rouge et Bulletin international des Sociétés de la Croix-Rouge*, 2008, 33(387): 1-10
- [9] SUN Y G, SUN L. The design of avionics system interfaces emulation and verification platform based on QAR data[J]. *Applied Mechanics and Materials*, 2014, 668/669: 879-883
- [10] 汪磊, 孙瑞山, 吴昌旭, 等. 基于飞行 QAR 数据的重着陆风险定量评价模型[J]. *中国安全科学学报*, 2014, 24(2): 88-92
WANG Lei, SUN Ruishan, WU Changxu, et al. Quantitative evaluation model of heavy landing risk based on flight QAR data [J]. *China Safety Science Journal*, 2014, 24(2): 88-92 (in Chinese)
- [11] ZHONG J, WANG D, LI C. A nonparametric health index and its statistical threshold for machine condition monitoring[J]. *Measurement*, 2020, 167: 108290
- [12] HE Q, YAN R, KONG F, et al. Machine condition monitoring using principal component representations[J]. *Mechanical Systems and Signal Processing*, 2009, 23(2): 446-466
- [13] 程宏波, 伦利, 康琛, 等. 一种基于多元统计分析的变压器状态评判方法[J]. *电网技术*, 2018, 42(2): 2719-2724
CHENG Hongbo, LUN Li, KANG Chen, et al. A transformer state evaluation method based on multivariate statistical analysis [J]. *Power Grid Technology*, 2018, 42(2): 2719-2724 (in Chinese)
- [14] PEDREGAL D J, CARMEN C M. State space models for condition monitoring: a case study[J]. *Reliability Engineering & System Safety*, 2006, 91(2): 171-180
- [15] 宋伟杰, 关山, 庞弘阳. 基于希尔伯特-黄变换和等距特征映射的刀具磨损状态监测[J]. *组合机床与自动化加工技术*, 2018, 6: 114-118
SONG Weijie, GUAN Shan, PANG Hongyang. Tool wear state monitoring based on Hilbert-Yellow transform and equidistant feature mapping[J]. *Modular Machine Tool and Automatic Processing Technology*, 2018, 6: 114-118 (in Chinese)
- [16] ATTOUI I, BOUTASSETA N, FERGANI N, et al. Novel machinery monitoring strategy based on time-frequency domain similarity measurement with limited labeled data[J]. *IEEE Trans on Instrumentation and Measurement*, 2020, 70: 3500708
- [17] CAO W, CHEN W, DONG G, et al. Wear condition monitoring and working pattern recognition of piston rings and cylinder liners using on-line visual ferrograph[J]. *Tribology Transactions*, 2014, 57(4): 690-699
- [18] 孟光, 尤明懿. 基于状态监测的设备寿命预测与预防维护规划研究进展[J]. *振动与冲击*, 2011, 30(8): 1-11
MENG Guang, YOU Mingyi. Research progress of equipment life prediction and preventive maintenance planning based on condition monitoring[J]. *Journal of Vibration and Shock*, 2011, 30(8): 1-11 (in Chinese)
- [19] DALKIRAN F Y, TORAMAN M. Predicting thrust of aircraft using artificial neural networks[J]. *Aircraft Engineering and Aerospace Technology*, 2021, 93(1): 35-41
- [20] WANG S, ZHANG N, WU L, et al. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method[J]. *Renewable Energy*, 2016, 94: 629-636
- [21] 艾剑良, 杨曦中. 一种基于自适应神经网络的航空发动机故障诊断方法[J]. *中国科学: 技术科学*, 2018, 48(3): 326-335
AI Jianliang, YANG Xizhong. An aero-engine fault diagnosis method based on adaptive neural network[J]. *Science China Technology Sciences*, 2018, 48(3): 326-335 (in Chinese)
- [22] ZHOU J, QIU Y, ZHU S, et al. Optimization of support vector machine through the use of metaheuristic algorithms in forecasting TBM advance rate[J]. *Engineering Applications of Artificial Intelligence*, 2021, 97(1): 104015
- [23] 崔建国, 李胜男, 于明月, 等. 基于组合预测模型的飞机刹车系统性能趋势预测分析[J]. *科学技术与工程*, 2018, 18(31): 179-183
CUI Jianguo, LI Shengnan, YU Mingyue, et al. Performance trend prediction analysis of aircraft brake system based on combination prediction model[J]. *Science Technology and Engineering*, 2018, 18(31): 179-183 (in Chinese)
- [24] 李耀华, 王星州. 飞机液压系统故障诊断[J]. *计算机工程与应用*, 2019, 55(5): 232-236
LI Yaohua, WANG Xingzhou. Fault diagnosis of aircraft hydraulic system[J]. *Computer Engineering and Applications*, 2019, 55(5): 232-236 (in Chinese)

- [25] 谷润平, 来靖晗, 魏志强. 基于改进 BP 神经网络的飞行落地剩油预测方法[J]. 飞行力学, 2020, 38(4): 76-80
GU Runping, LAI Jinghan, WEI Zhiqiang. Flight residual oil prediction method based on improved BP neural network[J]. Journal of Flight Mechanics, 2020, 38(4): 76-80 (in Chinese)
- [26] 徐怡, 王华伟, 熊明兰. 基于 PCA-GA-BP 的民航风险评价体系和预测模型[J]. 舰船电子工程, 2021, 41(2): 77-81
XU Yi, WANG Huawei, XIONG Minglan. Civil aviation risk assessment system and prediction model based on PCA-GA-BP[J]. Ship Electronic Engineering, 2021, 41(2): 77-81 (in Chinese)
- [27] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95(1): 51-67

Landing gear condition monitoring based on back propagation neural network-based on multi-strategy cooperative optimization

FENG Yunwen¹, WANG Rui¹, LU Tao², CHEN Junyu¹, LU Cheng¹

(1.School of Aeronautic, Northwestern Polytechnical University, Xi'an 710072, China;
2.Beijing Institute of Aerospace Systems Engineering of China Aerospace, Beijing 100076, China)

Abstract: To effectively monitor the operation state of landing gear, a back propagation neural network-based on multi-strategy cooperative optimization (MSCO-BPNN) is proposed. The multi-strategy optimization algorithm is composed of chaotic mapping strategy, adaptive spiral capture strategy, crossover mutation strategy and whale optimization algorithm(WOA). WOA is applied to find the optimal hyperparameters of back propagation neural network (BPNN). The search efficiency, multi-local search ability and global search performance of model can be improved by using chaotic mapping strategy, adaptive spiral capture strategy and crossover mutation strategy. The BPNN with optimal hyperparameters is introduced to establish the implicit model of input parameters and output responses. Based on quick access recorder(QAR) data, landing gear left side brake temperature is act as the monitoring objective of this paper. The validity and applicability of MSCO-BPNN are verified by compared with WOA-BPNN, particle swarm optimization BPNN and traditional BPNN. The results show that MSCO-BPNN can monitor the operation status of landing gear with high efficiency and accuracy. The efforts of this paper provide a promising insight for the precise condition monitoring of complex structures.

Keywords: landing gear; whale optimization algorithm; quick access recorder; condition monitoring, back propagation neural network

引用格式:冯蕴雯, 王锐, 卢涛, 等. 基于多策略协同优化神经网络的起落架状态监测[J]. 西北工业大学学报, 2023, 41(2): 264-273
FENG Yunwen, WANG Rui, LU Tao, et al. Landing gear condition monitoring based on back propagation neural network-based on multi-strategy cooperative optimization[J]. Journal of Northwestern Polytechnical University, 2023, 41(2): 264-273 (in Chinese)