基于BO-BiLSTM-RBF的航空发动机气路故障诊断

王阿久[1],蔡开龙[2],何　森[3],戴郎杰[1],郑　球[4]
(南昌航空大学 飞行器工程学院[1],民航学院[2]:南昌 330063;3.中国航发南方工业有限公司,湖南株洲 412000;
4.航空工业江西洪都航空工业集团有限责任公司,南昌 330096)

摘要:针对航空发动机气路故障诊断中机器学习算法数据分析能力不足、深度学习算法收敛速度和效果不佳易陷入过拟合的问题,建立了一种基于贝叶斯算法(BO)优化双向长短时记忆(BiLSTM)网络结合径向基(RBF)神经网络的发动机气路故障诊断模型。采用BO对BiLSTM网络的初始学习率和L2正则化系数进行寻优,利用优化后的BiLSTM网络对发动机气路数据进行特征提取,使用RBF神经网络对提取到的抽象特征进行识别分类,开展故障诊断。结果表明:BO-BiLSTM-RBF模型准确率达95.88%,且其泛化能力、抗干扰能力和鲁棒性等均优于BiLSTM-RBF网络、BiLSTM网络、支持向量机(SVM)、RBF神经网络以及反向传播(BP)神经网络等模型,可有效地诊断发动机的单一或复合故障,为发动机故障诊断提供新的思路和方法。

关键词:故障诊断;气路故障;双向长短时记忆网络;贝叶斯优化;径向基神经网络;特征提取;航空发动机
中图分类号:V263.6　　**文献标识码**:A　　doi:10.13477/j.cnki.aeroengine.2025.06.012

Aeroengine Gas Path Fault Diagnosis Based on BO-BiLSTM-RBF

WANG A-jiu[1], CAI Kai-long[2], HE Sen[3], DAI Lang-jie[1], ZHENG Qiu[4]
(College of Aircraft Engineering[1], College of Civil Aviation[2], Nanchang Hangkong University: Nanchang 330063, China;
3. AECC South Industry Company Limited , Zhuzhou Hunan 412000, China;
4. AVIC Jiangxi Hongdu Aviation Industry Group Company Ltd., Nanchang 330096, China)

Abstract: To address the issues of insufficient data analysis capabilities of machine learning algorithms and poor convergence speed and ineffectiveness of deep learning algorithms prone to overfitting in aeroengine gas path fault diagnosis, a gas path fault diagnosis model based on bayesian optimization(BO) optimised bidirectional long and short-term memory (BiLSTM) network combined with radial basis function (RBF) neural network was established. BO was used to optimise the initial learning rate and L2 regularisation coefficient of the BiLSTM network, and the optimised BiLSTM network was employed to extract features from the aeroengine gas path data, and the RBF neural network was used to identify and classify the extracted abstract features for fault diagnosis. The results show that the BO-BiLSTM-RBF model achieves an accuracy rate of 95.88%, and its generalization ability, interference resistance, and robustness outperform models such as BiLSTM-RBF network, BiLSTM network, support vector machine (SVM), RBF neural network, and Back Propagation (BP) neural network. It can effectively diagnose both single and compound faults in the aeroengine, providing a novel approach for aeroengine fault diagnosis.

Key words: fault diagnosis; gas path faults; bidirectional long short-term memory network (BiLSTM); Bayesian optimization (BO); radial basis function (RBF) neural networks; feature extraction; aeroengine

0　引言

航空发动机结构复杂,通常工作在高压、高转速、宽温域、高振动的复杂工况下,长期服役易产生腐蚀、疲劳等各种损伤,使其性能降低乃至发生故障失效,甚至造成严重后果。因此,发动机气路故障诊断技术对保证发动机可靠性、安全性、测试性、维修性、保障性和环境适应性,预防飞行事故,减少经济损失等方面至关重要[1-3]。

发动机故障诊断及状态监控技术的研究一直以来备受关注。Lee等[4]将卷积神经网络用于轴承故障诊断,有效提高了轴承故障诊断准确率;Zhang等[5]利

收稿日期:2024-03-05　**基金项目**:江西省双千计划(JXSQ2018106057)资助
作者简介:王阿久(1999),男,在读硕士研究生。

引用格式:*王阿久,蔡开龙,何森,等.基于BO-BiLSTM-RBF的航空发动机气路故障诊断[J].航空发动机,2025,51(6):101-107.WANG Ajiu,CAI Kailong,HE Sen,et al.Aeroengine gas path fault diagnosis based on BO-BiLSTM-RBF[J].Aeroengine,2025,51(6):101-107.*

用深度神经网络对发动机进行故障诊断，具有较好的准确度和泛化性；Cui 等[6]建立了一种 GSA-SAE 模型应用于发动机气路故障诊断，其准确率高，收敛速度快，损失小；Zhao 等[7]提出了一种基于极限学习机和迁移学习的发动机气路故障诊断方法，算法训练速度快且性能稳定，能有效地进行故障诊断；Zhong 等[8]提出了一种基于支持向量机和卷积神经网络的迁移学习方法，并在发动机数据集上进行试验，表明其具有很强的故障辨识能力；Qu 等[9]利用遗传算法优化求解空间初始权值和阈值的反向传播（Back Propagation，BP）神经网络进行发动机故障诊断，网络精度高、收敛速度快；蒋丽英等[10]提出了一种基于主成分分析和深度置信网络相结合的发动机气路故障诊断方法，并验证了该方法的有效性。

浅层神经网络和支持向量机（Support Vector Machine，SVM）等机器学习方法存在数据分析能力的不足，深度学习算法当参数选择不当时收敛速度和效果不佳，容易陷入过拟合，泛化能力差。本文建立了一种基于 BO-BiLSTM-RBF 的故障诊断模型，采用贝叶斯优化（Bayesian Optimization，BO）算法对双向长短时记忆（Bidirectional Long Short-Term Memory，BiLSTM）网络的初始学习率和 L2 正则化系数进行了优化，并使用优化后的 BiLSTM 网络对发动机监测数据进行特征提取，得到能够表征数据故障特征且易于分类的特征向量，然后利用径向基（Radial Basis Function，RBF）神经网络对特征进行故障诊断。

1 发动机气路故障诊断原理

发动机是非线性强的复杂系统，气路故障占发动机故障的 90% 以上[11]。当发动机一旦发生气路故障，由于零件表面的积垢、腐蚀、磨损、外来物损伤、喷嘴堵塞、裂纹、密封件损坏等原因，使增压比降低、相似空气流量减小、涡轮效率降低。发动机故障诊断过程是发动机故障引起性能衰退的逆过程，即通过读取传感器中的测量参数，分析发动机性能参数，从而间接推断发动机的状态，以此实现故障判断。其中，性能参数的变化可直接反映发动机的实时状况，如果发动机出现了突发状况，可根据性能参数偏离正常值的程度来识别发动机是否发生故障[12]。发动机气路故障诊断原理如图 1 所示。

根据发动机气路故障诊断的原理得到气路故障

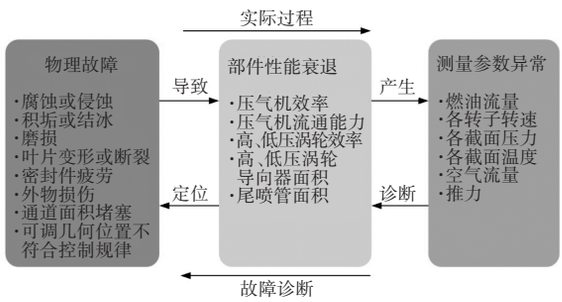

图 1 发动机气路故障诊断原理

诊断模型为

$$Y = f(X) \tag{1}$$

式中：$Y = [y_1, y_2, \cdots, y_n]$ 为故障诊断模型的输出，$y_i (i = 1,2,\cdots,n)$ 为气路的故障模式；$X = [x_1, x_2, \cdots, x_j]$ 为模型输入，$x_j (j = 1,2,\cdots,n)$ 为发动机传感器测量参数。

2 基于 BO-BiLSTM-RBF 的发动机气路故障诊断模型

基于 BO-BiLSTM-RBF 的发动机气路故障诊断模型如图 2 所示。贝叶斯算法优化初始学习率和 L2 正则化系数后的 BiLSTM 网络利用发动机数据的历史信息和未来信息，自行删除无用信息并更新存储信息，提取有利于分类且鲁棒性更强的抽象化特征，用 RBF 替换 BiLSTM 网络原有的 Softmax 分类器进行特征分类，从而达到故障诊断的目的。

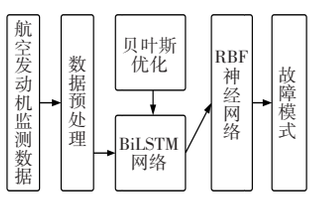

图 2 基于 BO-BiLSTM-RBF 的发动机气路故障诊断模型

2.1 LSTM 算法

标准循环神经网络（Recurrent Neural Network，RNN）对长文本进行学习时难以获取之前的信息，易出现“梯度消失”或“梯度爆炸”的情况，存在长时依赖问题[13]。长短时记忆（Long Short-Term Memory，LSTM）网络通过设计门限结构，即当前时刻的输入信息、遗忘门（Forget Gate）、输入门（Input Gate）和输出门（Output Gate），克服了 RNN 的缺陷[14]。使用 Sigmoid 函数[15]作为各门的激活函数，其输出范围为 (0,1)，用于定义各门是否打开及打开的程度，并赋予其遗忘或添加信息的能力。LSTM 单元结构如图 3 所示。

从图中可见，细胞状态是 LSTM 网络能否存储或遗忘信息的关键，C_{t-1} 到 C_t 为细胞状态更新信息的

过程。

遗忘门的计算方法为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{2}$$

式中：W_f为遗忘门权重；b_f为遗忘门偏置；σ为sigmoid函数。

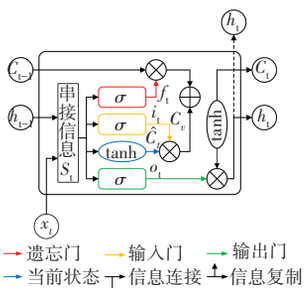

图3　LSTM单元结构

输入门的计算方法为

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{3}$$

式中：W_i为输入门权重；b_i为输入门偏置。

$\tilde{C}_t$的计算方法为

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \tag{4}$$

式中：W_C为信息候选值权重；b_C为信息候选值偏置；tanh为双曲正切函数。

联立式(2)~(4)得C_t的计算方法为

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \tag{5}$$

输出门输出的计算方法为

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{6}$$

式中：W_o为输出门权重；b_o为输出门偏置。

最后，当前LSTM单元的输出为

$$h_t = o_t \cdot \tanh(C_t) \tag{7}$$

2.2　BiLSTM算法

LSTM神经网络是单向的，可保留历史信息判断当前状态。每个时刻的输出依赖于过去时刻的输入值，无法利用未来时刻的信息。而BiLSTM神经网络则可以弥补LSTM的缺陷。BiLSTM单元的主体结构是由前向LSTM和后向LSTM2个单元组成，最终的输出为这2个单向LSTM输出的结合。BiLSTM的双向结构可同时利用数据的历史和未来信息，将2个方向的信息进行互补，从而提高网络的准确度和鲁棒性。BiLSTM网络结构如图4所示。

从图中可见，BiLSTM层由2层方向相反的LSTM层组成，联立式(2)~(7)，可得t时刻输出h_t与输入x_t和$t-1$时的输出h_{t-1}的函数，为简便计算过程定义该函数为

$$h_t = \mathrm{LSTM}(x_t, h_{t-1}) \tag{8}$$

由于BILSTM是由前向LSTM和后向LSTM构成，BILSTM前传层的输出$\overrightarrow{h}_t$为

$$\overrightarrow{h}_t = \mathrm{LSTM}(x_t, \overrightarrow{h}_{t-1}) \tag{9}$$

BILSTM的后传层输出$\overleftarrow{h}_t$为

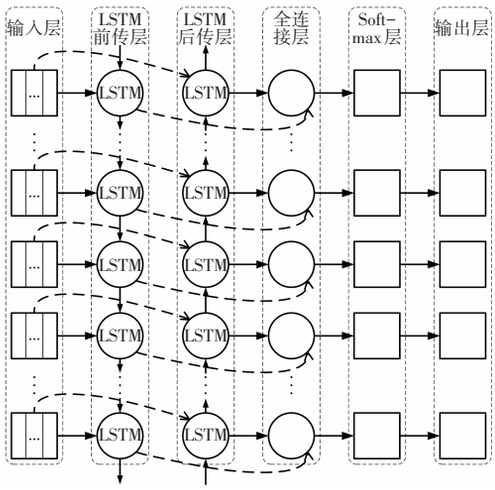

图4　BiLSTM网络结构

$$\overleftarrow{h}_t = \mathrm{LSTM}(x_t, \overleftarrow{h}_{t-1}) \tag{10}$$

BILSTM层在t时刻的输出y_t为

$$y_t = W_{\overrightarrow{h}y}\overrightarrow{h}_t + W_{\overleftarrow{h}y}\overleftarrow{h}_t + b_y \tag{11}$$

式中：$W_{\overrightarrow{h}y}$与$W_{\overleftarrow{h}y}$为前向LSTM和后向LSTM的权重；b_y为输出层偏置因子。

2.3　RBF神经网络

RBF神经网络是一种结构与BP神经网络类似的3层前馈神经网络。隐含层、输出层的激活函数分别为径向基函数、线性函数。RBF神经网络结构如图5所示。

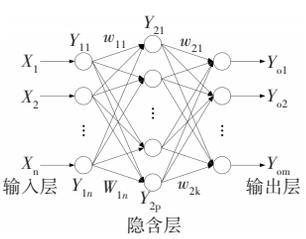

图5　RBF神经网络结构

其输入向量$X = [X_1, X_2, X_3, \cdots, X_n]^T$可直接映射到隐含层的空间，而输出向量$Y = [Y_{o1}, Y_{o2}, Y_{o3}, \cdots, Y_{om}]^T$是隐含层的线性组合。

若隐含层函数选用高斯函数，则其输出为

$$f_\phi(X, Y_{2i}) = G(\|X - Y_{2i}\|) = \exp\left(-\frac{\|X - Y_{2i}\|^2}{2\sigma_i^2}\right) \tag{12}$$

式中：$i = (1,2,\cdots,p)$；c_i、σ_i分别为高斯函数的中心、方差。

隐含层经权值分配后得到输出层

$$Y = \sum_{i=1}^{p} p_{ij}(w_2)_{ij} = \sum_{i=1}^{p}(w_2)_{ij} G(\|X - Y_{2i}\|) \tag{13}$$

式中：$i = (1,2,\cdots,p)$；$j = (1,2,\cdots,m)$；$(w_2)_{ij}$为连接隐含层和输出层的权值。

2.4　BO算法

隐含层神经元数目、初始学习率、迭代次数以及批大小等超参数直接影响神经网络的性能[16]。比如

初始学习率过大或过小都会导致收敛效果较差。因此，对神经网络超参数进行优化是必要的。BO 算法是一种全局优化算法，利用先验知识高效调节超参数，并以较少的初始样本点快速寻优，能在较少的评估次数时取得复杂目标函数的近似解。

BO 超参数优化的定义为[17]

$$x^* = \arg\min_{x \in X} f(x) \tag{14}$$

式中：$f(x)$为需要优化的目标函数；x 为超参数的 1 组设置取值；x^*为混合设计空间 X 中使 $f(x)$取得全局最优解的 x。

贝叶斯优化的过程如下[18]。

输入：n_0 为初始化点数量；N 为最大迭代次数；$g(x)$ 为代理模型；$\alpha(x|D)$ 为采集函数。

输出：最优候选评估点：$\{x^*, y^*\}$。

步骤：

1. 随机初始化 n_0 个点 X_{init}；

2. 评估得到 $f(X_{\text{init}})$，初始点集 $D_0=\{X_{\text{init}}, f(X_{\text{init}})\}$，令 $t=n_0$，当前数据集 $D_{t-1}=D_0$；

3. 当 $t < N$ 时，执行循环：

（1）基于当前点集 D_{t-1} 拟合代理模型 $g(x)$；

（2）最大化采集函数 $\alpha(x|D_{t-1})$确定下一个评估点 $x_t=\text{argmin}\ \alpha(x|D_{t-1})$；

（3）评估目标函数值 $f(x_t)$，更新点集 $D_t = D_{t-1} U \{x_t, f(x_t)\}$；

（4）令 $t=t+1$；

4. 输出最优候选评估点：$\{x^*, y^*\}$。

2.5 基于BO-BiLSTM-RBF的发动机气路故障诊断模型

基于 BO-BiLSTM-RBF 的发动机气路故障诊断流程如图 6 所示。具体步骤如下：

（1）获取发动机气路数据并进行预处理，划分训练集与测试集。

（2）使用 BO 算法对 BiLSTM 网络的初始学习率和 L2 正则化系数进行寻优。

（3）输入训练集对模型进行训练，优化并更新网络模型参数，使其在对测试集进行预测时拥有更好的效果。然后将 BiLSTM 网络提取到的数据特征输入到 RBF 神经网络，输出故障模式，完成故障诊断。

（4）结果分析，通过准确率、F1 分数等评价指标来评估模型故障诊断性能。

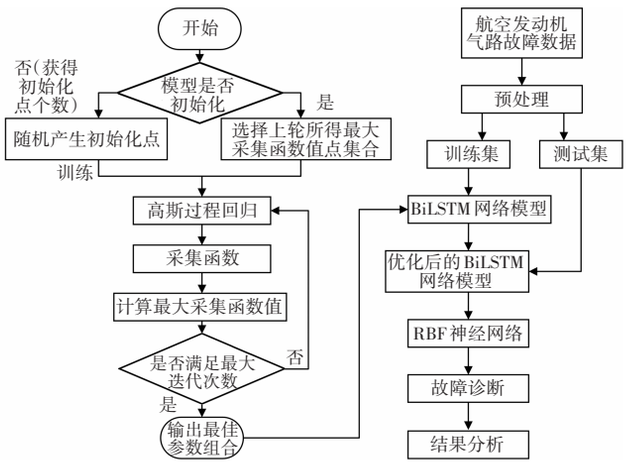

图 6 基于 BO-BiLSTM-RBF 的发动机气路故障诊断流程

3 试验与结果分析

3.1 试验数据获取

测量参数的选取对发动机故障诊断至关重要，参数过多时数据间强耦合性与参数过少时特征映射不完全都会影响诊断精度。故式（1）中 X 取主燃油流量 W_{f}、高压转子转速 N_{H}、低压转子转速 N_{L}、风扇出口压力 P_{21}、风扇出口温度 T_{21}、高压压气机出口压力 P_3、高压压气机出口温度 T_3、高压涡轮出口压力 P_5、低压涡轮出口压力 P_{55}、低压涡轮出口温度 T_{55}。本文采用对涡扇发动机部件级模型进行性能衰退模拟的方法获取试验所需数据。模拟仿真条件设置高度为 7500 m、Ma=0.75、大气总温为 239.40 K、大气总压为 39.5011 kPa。分别对高、低压压气机和高、低压涡轮 4 个部件进行故障模拟，得到 4 种单故障和 5 种复合故障，加上正常状态共 10 种模式，1572 个样本。

发动机参数传感器所采集的数据在工况、发动机自身因素及传感器测量误差的综合影响下常伴随噪声干扰。因此本文对试验数据施加 1% ~ 4% 强度的高斯白噪声。噪声添加公式为

$$x = x + K \cdot \sigma \cdot \text{rand}(\ ) \tag{15}$$

式中：x 为故障类型测量参数变化量矩阵；K 为添加噪声强度百分比；σ 为测量参数变化向量的标准差；rand( ) 为服从正态分布的随机函数。

对测量参数不同量纲的数据归一化

$$x' = \frac{x - (x)_{\min}}{(x)_{\max} - (x)_{\min}} \tag{16}$$

式中：x 为发动机气路数据；x' 为归一化后的数据。

3.2 评价指标

本文采用准确率、精准率、召回率和 F1 分数 4 类

评价指标对BO-BiLSTM-RBF模型进行性能评估。各评价指标的计算公式为

$$\begin{cases} \text{准确率} = \dfrac{T_P + T_N}{T_P + F_P + T_N + F_N} \\ \text{精确率} = \dfrac{T_P}{T_P + F_P} \\ \text{召回率} = \dfrac{T_P}{T_P + F_N} \\ F1 = \dfrac{2*T_P}{2*T_P + F_P + F_N} \end{cases} \tag{17}$$

式中：T_P为真正例；F_P为假正例；T_N为真负例；F_N为假负例。

3.3　仿真试验与结果分析

为探究神经元节点数、BO算法迭代次数、训练集占比及噪声干扰对BO-BiLSTM-RBF模型诊断性能的影响，分别进行验证分析。由于模型在发动机气路故障诊断中对诊断结果具有波动性，为证实模型的可靠性和可信度，试验最终结果均取各模型10次重复试验结果的平均值。

神经网络的隐含层节点数与网络的性能密切相关，但BiLSTM网络的特征提取能力并非与神经元节点数呈正相关。选取合适的神经元节点数对故障诊断模型非常关键。为了避免任取神经元节点数造成模型诊断准确率低、泛化能力差以及训练时间长等问题，经过反复试验，神经元节点数在20~60内既可保证良好的诊断性能，又能避免训练时间过长，故本文建立了神经元节点数分别为20、30、40、50、60等5种模型进行对比试验。为保证BO算法寻优效果，迭代次数均设置为25，训练集占比为0.6。不同神经元节点数的模型诊断准确率对比如图7所示。

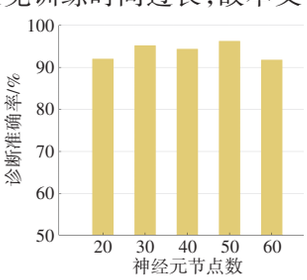

图7　不同神经元节点数的模型诊断准确率对比

从图中可见，神经元节点数为30、40、50、60的模型准确率均在94%以上，神经元节点数为20时准确率稍低，故神经元节点数在30以上时模型即可取得较好拟合效果，且50个神经元节点的模型准确率达95.81%，故后续试验均采用50个神经元节点。

BO算法迭代次数对模型初始学习率和L2正则化系数寻优有直接影响。迭代次数过少，BO算法难以找到最佳参数组合；迭代次数过多，寻优时间长，计算量大，对试验设备要求较高。为探究BO算法不同迭代次数对模型诊断准确率的影响，将迭代次数分别设置为10、15、20、25、30进行对比试验。BO算法迭代次数与模型诊断准确率的关系如图8所示。

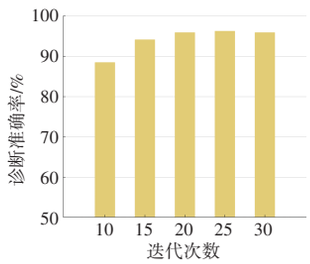

图8　BO算法迭代次数与模型诊断准确率的关系

从图中可见，随着迭代次数从15增加到20，模型诊断准确率逐渐提高；而迭代次数超过20后，准确率基本保持不变。故模型在约20次迭代时可获得最佳初始学习率和L2正则化系数，此时模型平均准确率为95.88%。为兼顾诊断准确率和寻优成本，在后续试验中的BO算法迭代次数设置为20。

以其中1次测试为例，BO算法寻优过程和最小目标值计算分别如图9、10所示。经过18次迭代寻得最优超参数组合：初始学习率为0.0374，L2正则化系数为2.5276×10^{-6}，此时模型的诊断准确率达到最优值为96.82%。测试集混淆矩阵如图11所示，模型对各故障模式均取得了良好的诊断效果。

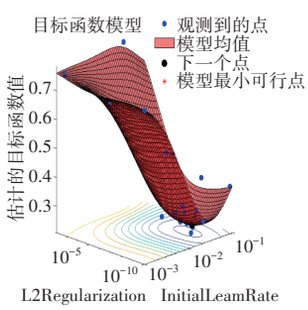

图9　BO算法寻优过程

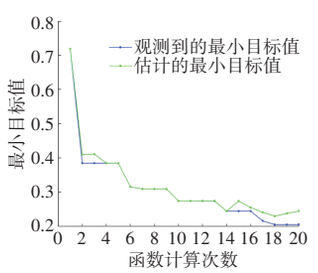

图10　最小目标值计算

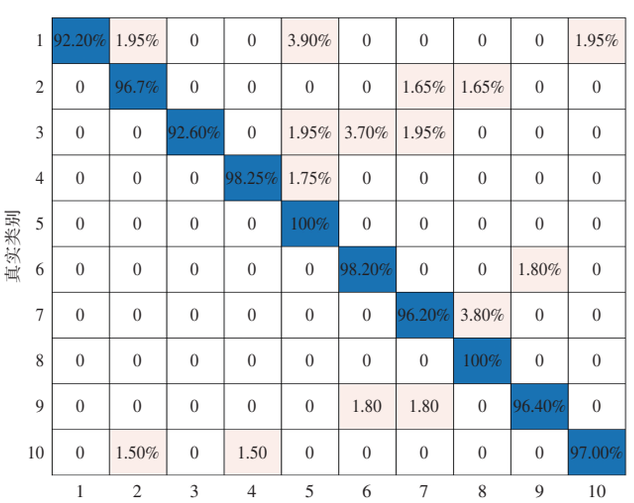

图11　测试集混淆矩阵

为探究训练集占比对模型诊断准确率的影响，将训练集占比依次设置为0.5、0.6、0.7、0.8，并与BiLSTM-RBF、BiLSTM进行对比试验。3种模型不同训练集占比的诊断准确率对比试验结果如图12所示。

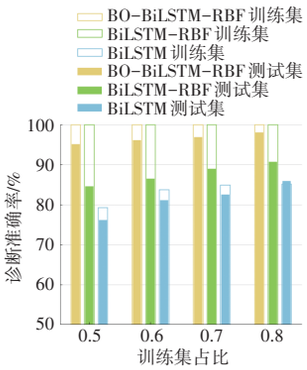

图12 3种模型不同训练集占比的诊断准确率对比

从图中可见，BO-BiLSTM-RBF模型、BiLSTM-RBF模型、BiLSTM模型的测试集诊断准确率均随训练集占比的增大而增大；在4种不同的训练集占比中，BiLSTM-RBF模型相较于BiLSTM模型，其训练集诊断准确率明显提高，接近100%，但测试集诊断准确率提高较小，其原因是BiLSTM-RBF模型出现了严重的过拟合，导致模型泛化能力差；BO-BiLSTM-RBF模型通过BO算法寻优后获得最佳超参数组合，对于不同训练集占比，其训练集诊断准确率接近100%，且测试集诊断准确率均在95%以上，不仅准确率高，且泛化能力、鲁棒性强。

为验证BO-BiLSTM-RBF模型在发动机气路故障诊断中的优越性，分别采用BiLSTM-RBF、BiLSTM、SVM、RBF、BP等模型进行对比试验。训练集占比为0.6，对比模型参数均为默认设置，通过10次独立试验分别取得不同模型的准确率、精确率、召回率、F1分数的平均值，结果见表1。从表1中可见，BO-BiLSTM-RBF模型各评价指标均为最优，诊断效果优越。

表1 诊断模型性能对比

模型	准确率	精确率	召回率	F1分数
BiLSTM-RBF	86.65	85.87	86.22	86.75
BiLSTM	81.88	81.60	82.19	82.03
SVM	84.90	84.98	84.29	85.11
RBF	85.85	85.47	85.96	85.28
BP	83.79	83.92	83.52	83.92
BO-BiLSTM-RBF	95.88	96.01	95.50	95.67

为验证BO-BiLSTM-RBF模型的抗干扰能力，本文使用相同的数据集在相同的设置下，分别建立了BiLSTM-RBF、BiLSTM、SVM、RBF以及BP等模型进行对比试验，设置训练集占比为0.6，以上几种方法在不同噪声强度下的准确率如图13所示。

从图中可见，在不同的噪声强度下，BO-BiLSTM-RBF模型的准确率明显大于其他5种模型的，且随噪声强度增大，各模型的准确率均呈降低趋势，但BO-BiLSTM网络受噪声影响较小，说明BO-BiLSTM-RBF模型的抗干扰能力较强。

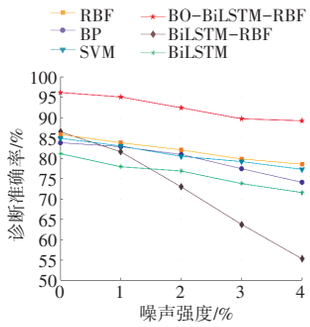

图13 几种方法在不同噪声强度下的准确率

4 结论

（1）BO-BiLSTM-RBF模型的神经元节点数为50、BO算法迭代次数大于20时在不同的训练集占比中均可取得很好的诊断效果；

（2）BO-BiLSTM-RBF模型相较于BiLSTM-RBF、BiLSTM、SVM、RBF、BP等模型在发动机气路故障中具有绝对优势，且具有良好的泛化能力和抗噪能力，鲁棒性强，但BO算法寻优需要一定时间。

参考文献：

[1] 向巧. 航空发动机维修工程管理[M]. 北京：机械工业出版社，2013：6-7.
XIANG Qiao. Aircraft engine maintenance engineering management [M]. Beijing: Machinery Industry Press, 2013: 6-7.(in Chinese)

[2] 李少尘，陈敏，胡金涛，等. 航空燃气涡轮发动机气路故障诊断进展[J]. 航空发动机，2022，48(2)：33-49.
LI Shaochen, CHEN Min, HU Jintao, et al. A review of research progress on aircraft gas turbine engines gas path fault diagnosis[J]. Aeroengine, 2022, 48(2): 33-49. (in Chinese)

[3] 车畅畅，王华伟，倪晓梅，等. 基于GSP仿真和SDAE的航空发动机故障诊断[J]. 航空发动机，2022，48(1)：13-18.
CHE Changchang, WANG Huawei, NI Xiaomei, et al. Aeroengine fault diagnosis based on GSP simulation and SDAE[J]. Aeroengine, 2022, 48(1): 13-18. (in Chinese)

[4] Lee D, Siu V, Cruz R, et al. Convolutional neural net and bearing fault analysis[C]// Proceedings of the International Conference on Data Science(ICDATA).Las Vegas: World Comp, 2016: 194-200.

[5] Zhang K, Lin B, Chen J, et al. Aero-Engine surge fault diagnosis using deep neural network[J]. Computer Systems Science and Engineering, 2022, 42(1): 351-360.

[6] Cui J G, Yan T, Xiao C, et al. An effective fault diagnosis method for aero engines based on GSA-SAE[J]. Transactions of Nanjing University of Aeronautics andAstronautics, 2020, 37(5): 750-757.

[7] Zhao Y P, Chen Y B. Extreme learning machine based transfer learning for aero engine fault diagnosis[J]. AeroSpace Science and Technology, 2022, 121: 107311.

[8] Zhong S S, Fu S, Lin L. A novel gas turbine fault diagnosis method based on transfer learning with CNN[J]. Measurement, 2019, 137:

435-453.

[9] Qu H C, Huang Y Q. The research on aero-engine gas path fault diagnosis by genetic algorithm- BP neural network [J]. Hydromechatronics Engineering,2015,43(18):31-36.

[10] 蒋丽英,栗文龙,崔建国,等. 基于PCA与DBN的航空发动机气路系统故障诊断[J]. 沈阳航空航天大学学报,2019,36(1):57-62.
JIANG Liying,LI Wenlong,CUI Jianguo,et al. Fault diagnosis of aero-engine gas path system based on PCA and DBN[J].Jurnal of Shenyang Aerospace University,2019,36(1):57-62.(in Chinese)

[11] 黄金泉,王启航,鲁峰. 航空发动机气路故障诊断研究现状与展望[J]. 南京航空航天大学学报,2020,52(4):507-522.
HUANG Jinquan,WANG Qihang,LU Feng. Research status and prospect of gas path fault diagnosis for aeroengine [J]. Journal of Nanjing University of Aeronautics and Astronautics, 2020,52(4):507-522.(in Chinese)

[12] 赵潇雅,郜志英,周晓敏,等. 基于FDA-LSTM的冷轧过程多源异构时序数据处理及颤振预测[J]. 振动与冲击,2022,41(22):202-210.
ZHAO Xiaoya,GAO Zhiying,ZHOU Xiaomin,et al. Multisource heterogeneous time series data processing and chatter prediction for cold rolling process based on FDA-LSTM[J]. Vibration and Shock, 2022, 41(22):202-210.(in Chinese)

[13] Volponi A J, Depold H, Ganguli R, et al. The use of kalman filter and neural network methodologies in gas turbine performance diagnostics: a comparative study[J]. Journal of Engineering for Gas Turbines and Power-transactions of the ASME,2003,125(4):917-924.

[14] Liu H,Zhou J,Zheng Y, et al. Fault diagnosis of rolling bearings with recurrent neural network-based auto encoders[J]. ISA Transactions, 2018,77:167-178.

[15] 周玉,房倩,裴泽宣,等. 基于改进麻雀搜索算法优化LSTM的滚动轴承故障诊断[J]. 工程科学与技术,2024,56(2):1-10.
ZHOU Yu,FANG Qian,PEI Zexuan,et al. Rolling bearing fault diagnosis based on improved sparrow search algorithm optimized LSTM [J]. Engineering Science and Technology, 2024, 56(2): 1-10.(in Chinese)

[16] 王雷,何坤,李宗帅,等. 基于BiLSTM-Attention的迁移学习变工况故障识别方法研究[J]. 电子测量与仪器学报,2023,37(7):205-212.
WANG Lei,HE Kun,LI Zongshuai, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions [J]. Journal of Electronic Measurement and Instrumentation, 2023,37(7):205-212.(in Chinese)

[17] 张乐,彭先龙,朱华双. 贝叶斯优化TQWT参数在轴承故障诊断中的应用[J]. 机械科学与技术,2024,43(3):504-512.
ZHANG Le, PENG Xianlong, ZHU Huashuang. Applying bayesian optimization of parameters of tunable quality-factor wavelet transform to bearing fault [J]. Mechanical Science and Technology for Aerospace Engineering, 2024,43(3):504-512.(in Chinese)

[18] Fast M, Assadi M, De S. Development and multiutility of an ANN model for an industrial gas turbine[J]. Applied Energy, 2009,86(1):9-17.

（编辑：贺红井）