

DOI:10.19651/j.cnki.emt.2416037

基于 CNN-BES-ELM 的航空发动机 气路故障诊断研究*

戴郎杰¹ 蔡开龙² 王阿久¹ 黄菲¹

(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)

摘要: 针对航空发动机运行过程中出现的气路故障问题,提出了一种基于卷积神经网络(CNN)结合秃鹰搜索算法(BES)优化极限学习机(ELM)的航空发动机气路故障诊断模型。通过CNN对航空发动机气路数据进行学习并提取出隐藏在数据中的故障特征,引入BES算法对ELM的权重和偏置进行寻优,使用优化后的ELM对CNN所提取的抽象特征进行分类,从而达到故障诊断的目的。实验结果表明,基于CNN-BES-ELM的模型其平均准确率达到97.80%,较CNN-ELM、CNN和ELM等方法分别提高了2.7%、5.4%和7.35%,较常用的深度学习模型如深度置信网络(DBN)和堆叠自编码器(SAE),其准确率分别提高了5.4%和3.4%;并且在随机噪声、高斯噪声和椒盐噪声等噪声环境下仍保有90%以上的准确率,整体表现出良好的诊断性能、泛化能力和抗噪能力,为其在航空发动机气路故障诊断中的实际应用提供了理论依据。

关键词: 航空发动机;故障诊断;卷积神经网络;秃鹰搜索算法;极限学习机

中图分类号: TN707 **文献标识码:** A **国家标准学科分类代码:** 590

Research on aero-engine gas path fault diagnosis based on CNN-BES-ELM

Dai Langjie¹ Cai Kailong² Wang Ajiu¹ Huang Fei¹

(1. College of Aircraft Engineering, Nanchang Hang Kong University, Nanchang 330063, China;

2. College of Aviation, Nanchang Hang Kong University, Nanchang 330063, China)

Abstract: Aiming at the airway fault problems occurring during the operation of aero-engine, an aero-engine airway fault diagnosis model based on Convolutional Neural Network (CNN) combined with Bald Eagle Search Algorithm (BES) Optimized Extreme Learning Machine (ELM) is proposed. The aero-engine airway data are learned by CNN and the fault features hidden in the data are extracted, the BES algorithm is introduced to optimize the weights and biases of the ELM, and the optimized ELM is used to classify the abstract features extracted by the CNN, so as to achieve the purpose of fault diagnosis. The experimental results show that the CNN-BES-ELM-based model achieves an average accuracy of 97.80%, which is 2.7%, 5.4% and 7.35% higher than that of CNN-ELM, CNN and ELM, respectively, and compared with commonly used deep learning models such as Deep Belief Network (DBN) and Stacked Auto Encoder (SAE), the accuracy is improved by 5.4% and 3.4%; and still retains more than 90% accuracy in noise environments such as random noise, Gaussian noise and pretzel noise, which overall shows good diagnostic performance, generalization ability and noise immunity, and provides a theoretical basis for its practical application in aero-engine airway fault diagnosis.

Keywords: aero-engine; fault diagnosis; convolutional neural network; bald eagle search algorithm; extreme learning machine

0 引言

飞行安全问题是飞机的生命线,是机上工作得以开展

的基础。航空发动机作为飞机的动力装置,随着工作循环次数的增加,将会不可避免地出现性能下降的问题。发动机一旦出现性能下降或发生突变故障,轻则导致飞机迫降,

收稿日期:2024-05-14

* 基金项目:江西省双千计划(jxsq2018106057)项目资助

影响航行任务;重则机毁人亡,造成难以估量的灾难和损失^[1]。因此,保障航空发动机在运行期间的安全性和可靠性至关重要。相关研究表明,发动机故障中约 90%由气路部件故障引起,而气路部件的维修费用约占发动机维修成本的 60%^[2],大多数发动机设备问题源于循环气体部件故障。

航空发动机故障诊断因其重要意义,历来是国内外专家学者研究的热点。崔建国等^[3]提出了一种基于改进的灰狼算法(improved gray wolf optimization, IGWO)优化核极限学习机(kernel extreme learning machine, KELM)的航空发动机故障诊断方法,有效提高了航空发动机故障诊断准确率。刘海瑞等^[4]提出一种基于自适应粒子群算法(adaptive particle swarm optimization, APSO)优化的最小二乘支持向量机(least squares support vector machine, LSSVM),并对滑油系统中轴承磨屑进行在线监测的故障诊断及寿命预测,具有较好的准确度和泛化性。朱海龙等^[5]提出一种基于证据推理和置信规则库的故障预测模型,该模型可以准确预测涡扇发动机的故障概率。吕卫民等^[6]将时间卷积神经网络(temporal convolutional network, TCN)与轻量梯度提升机(light gradient boosting machine, LGBM)相结合,对某型军用小涵道比涡扇发动机进行故障诊断,该方法具有出色的故障辨识能力。王月等^[7]针对航空发动机性能参数的强噪声和特征提取困难问题,提出了一种基于孪生减元注意力网络的故障诊断模型,并在 CFM56-5B 系列发动机的监测数据上取得较高准确率。Benyounes 等^[8]通过自适应模糊神经网络对发动机进行建模并以此进行故障诊断。Zhao 等^[9]通过遗传算法对反向传播神经网络的初始权值和阈值进行优化,实现了航空发动机故障诊断的高精度和快速收敛。Zhong 等^[10]提出了一种基于支持向量机(support vector machine, SVM)和卷积神经网络(convolutional neural network, CNN)的迁移学习方法(CNN-SVM),并在 CFM56 型号系列发动机数据集上进行实验,展现出很强的故障辨识能力。Chen 等^[11]提出了一种基于一维卷积神经网络和递归神经网络的航空发动机气路故障诊断模型,该方法诊断性能优异。Zhou 等^[12]提出了基于极端梯度提升(xtreme gradient boosting, XGBoost)优化 CNN 的燃气轮机故障诊断模型,该方法在诊断准确率、泛化能力方面表现出色。

卷积神经网络因其逐层交替的卷积层和池化层结构,在特征提取方面表现出色。但网络采用梯度下降法来寻找最优权值,导致网络在训练过程中耗时较长。极限学习机(extreme learning machine, ELM)因其出色的分类能力、较快的训练速度和较强的泛化能力被广泛运用于航空发动机故障诊断。然而,在训练时,ELM 会随机初始化输入层到隐藏层之间的权重和隐含层偏置,这可能导致模型的泛化性能受到影响,从而影响故障诊断结果。

根据上述问题本文提出了一种基于 CNN-BES-ELM

的航空发动机故障诊断模型。该模型首先利用 CNN 强大的特征提取能力对航空发动机气路数据进行特征提取,得到能够表征数据故障特征且易于分类的特征向量;其次,采用秃鹰搜索算法(bald eagle search algorithm, BES)对 ELM 中输入层到隐含层的权重和隐含层偏置进行优化,旨在提高其分类准确率,进而提升其泛化性能。最后,使用优化后的 ELM 替换 CNN 中原有的 Softmax 分类层进行分类,旨在解决 CNN 训练时间过长的问题和提升模型泛化性能。

1 航空发动机气路故障诊断模型

1.1 故障诊断原理

在航空发动机服役过程中,随着工作循环次数的增加,发动机气路部件会出现腐蚀、侵蚀、密封件损坏等故障,这些故障可能导致发动机的部件尺寸发生变化,进而导致部件性能退化^[13]。这些变化不仅会直接影响故障部件的自身功能,更会对发动机整体性能产生影响,表现为机载传感器测量参数的变化。航空发动机气路故障诊断原理如图 1 所示。

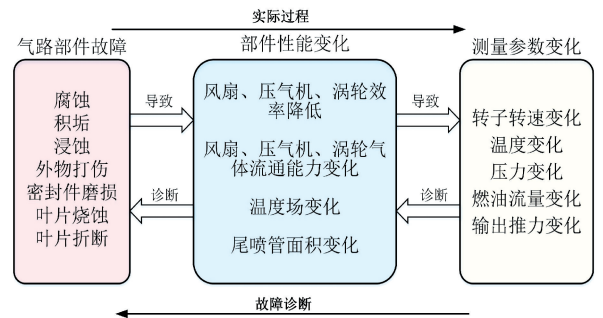


图 1 航空发动机故障诊断原理

Fig. 1 Aero engine fault diagnosis schematic

由图 1 可知,航空发动机气路故障诊断过程是航空发动机气路故障形成过程的逆过程。通过观测发动机可测量参数的变化来推断气路部件的性能变化,建立测量参数和发动机气路部件故障模式之间的非线性映射关系,并以此进一步定位产生故障的气路部件和确定故障模式,指导后续的故障维修。

1.2 气路故障诊断模型

本文采用基于数据驱动的故障诊断模型^[14],数据驱动的故障诊断模型只需要以发动机机载传感器采集的数据为基础进行故障诊断,无需考虑所诊断机械设备的物理结构^[15]。由航空发动机气路故障诊断的原理,得到其气路故障诊断模型为:

$$\mathbf{Y} = f(\mathbf{X}) \quad (1)$$

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

2 故障数据获取与模型输入输出参数确定

2.1 部件故障模拟

航空发动机气路部件流量和效率的变化是航空发动机存在气路故障最直接的体现,但是实际工作中无法直接获得部件的效率和流量值。部件流量和效率值的变化会引起发动机测量参数的变化,在航空发动机气路故障诊断中,通常依赖于转速、温度、压力等可测量的发动机参数,这些参数能够反映发动机的运行状态和性能特征,因此通过分析这些参数的变化趋势和异常模式,可以间接推断出部件可能存在的故障类型和模式^[6]。

由于真实发动机的故障样本数量较少,故本文通过某型军用涡扇发动机非线性部件气动热力学模型模拟故障来获得对应故障数据。故障模拟仿真条件设置为:高度 7.5 km,马赫数(Ma)0.75。模拟风扇(Fan)、压气机(high pressure compressor, HPC)、高低压涡轮(high pressure turbine & low pressure turbine, HPT&LPT)4 个部件的单一和复合故障。发动机部件的故障模拟如表 1 所示。

表 1 各故障模式对应气路部件

Table 1 Failure modes correspond to airline components

部件	故障模式								
	1	2	3	4	5	6	7	8	9
Fan	F	—	—	—	F	—	F	F	—
HPC	—	F	—	—	F	F	F	—	—
HPT	—	—	F	—	—	F	F	F	—
LPT	—	—	—	F	—	—	—	F	—

如表 1 所示,“F”表示该故障模式下发生故障的部件,“—”表示该故障模式下未发生故障的部件。除正常状态 9 之外,每种故障模式均对应着一个或多个航空发动机气路部件故障。共得到部件单一故障 4 种,模式 1~4;多部件复合故障 4 种,标号 5~8;正常状态 1 种,模式 9。

将不同故障模式下的气路部件变化带入航空发动机非线性部件级模型中,得到高度为 7.5 km,马赫数为 0.75 状态下的航空发动机气路数据,共得到 1 250 组的气路数据,具体如表 2 所示。

由于航空发动机各气路数据的量纲不同,各气路参数数据之间的大小差异过大,所以在训练前对数据进行归一化处理。本文选用 min-max 标准化,其优点是在对数据进行归一化的同时又不改变数据的分布,其计算公式为:

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2)$$

式中: $\min(x)$ 和 $\max(x)$ 分别表示 x 的最小值和最大值。通过归一化,使数据处于 $[0, 1]$ 区间内,同时对数据进行无量纲化,避免各个测量参数中不同量纲对故障诊断结果的影响。

表 2 航空发动机故障模式与样本数

Table 2 Aero-engine failure modes and sample size

故障标签	故障部件	故障形式	样本数目/组
1	风扇		128
2	高压压气机	单部件	147
3	高压涡轮	退化故障	136
4	低压涡轮		142
5	风扇 & 高压压气机		134
6	高压压气机 & 高压涡轮	多部件	131
7	风扇 & 高压压气机 & 高压涡轮	耦合故障	144
8	风扇 & 高压涡轮 & 低压涡轮		138
9	—	正常运行	150

2.2 故障诊断模型的输入与输出

在航空发动机故障诊断中,测量参数个数的精准选择至关重要。如果选取的气路测量参数过多,会导致数据处理的复杂性剧增,使得诊断算法难以有效工作。

另一方面,如果选取的气路测量参数过少,虽然能简化数据处理过程,但可能无法全面反映发动机的工作状态。某些关键信息的缺失可能导致诊断系统无法准确识别故障类型或定位故障位置,从而影响到诊断结果的准确性和可靠性。

经过综合考虑,本文选取燃油流量(w_f)、高压压气机转速(N_H)、风扇转速(N_L)、风扇出口总温总压(T_{21} 和 P_{21})、燃烧室进口总温总压(T_3 和 P_3)、低压涡轮出口总温总压(T_{55} 和 P_{55}) 等参数作为故障诊断模型的输入。表 1 中所示的故障模式作为故障诊断模型的输出。

3 基于 CNN-BES-ELM 的航空发动机气路故障诊断模型构建

基于 CNN-BES-ELM 的航空发动机气路故障诊断模型如图 2 所示。通过 CNN 强大的特征提取能力,提取航空发动机气路数据中隐含的故障信息,提取成便于分类且鲁棒性更强的抽象化特征,有利于 ELM 对数据进行分类识别。使用 BES 对 ELM 隐含层的权重和偏置进行寻优,以减少因其随机初始化对诊断结果带来的影响。通过 ELM 代替 CNN 原有的 Softmax 层进行特征的分类,最终实现对航空发动机气路的故障诊断。

3.1 卷积神经网络

卷积神经网络(CNN)是一种特殊的深层神经网络模型,具有很强的特征提取能力。CNN 能够学习并提取输入数据的局部和层次化特征,通过卷积和池化操作,有效捕捉数据里隐藏的故障特征信息,CNN 的基础结构如图 3 所示。

CNN 主要结构包括输入层、卷积层、池化层、全连接层和 Softmax 层。在 CNN 中,卷积层之后通常设置有一个池




图 2 基于 CNN-BES-ELM 的故障诊断模型

Fig. 2 Fault diagnosis model based on CNN-BES-ELM




图 3 卷积神经网络基本结构

Fig. 3 Basic structure of convolutional neural networks

化层,这两个层通常以卷积-池化对的形式出现。根据网络执行的任务,可以自行选择卷积-池化对的数量。这种结构配置有助于优化网络的整体架构,增强模型的性能。

卷积层是 CNN 的核心组成部分,它包含多个卷积核。每个卷积核在输入数据上进行卷积操作以提取特征,其运算表示为^[17]:

$$X^l = f(W^l * X^{l-1} + b^l) \quad (3)$$

式中: X^l 是第 l 层的输出特征图; W^l 是待优化的卷积核权重张量; b^l 是第 l 层的偏置项; $*$ 表示卷积运算; $f(\cdot)$ 代表激活函数,通过这些元素和操作的组合,网络能够学习和提取输入数据的特征。

池化层通常位于卷积层之后,用于对特征进行下采样,以减少数据的空间尺寸和计算复杂度^[18]。池化操作通常包括最大池化(max pooling)和平均池化(average pooling)等,它们通过选择或计算特征中的局部区域的最大值或平均值来降低维度。

$$X = f[\alpha S(x) + b] \quad (4)$$

式中: X 为池化层输出; $f(\cdot)$ 代表激活函数; α 为采样系数; b 为偏置。

全连接层(fully connected layer):在卷积层和池化层之后,通常会连接一个或多个全连接层^[19]。全连接层的每个神经元与前一层的所有神经元相连,用于整合前面层提取的特征,并输出最终的预测结果。

输出层(output layer):输出层是 CNN 的最后一层,它根据具体任务输出相应的结果。对于分类任务,输出层通常使用 Softmax 函数来输出分类类别。

3.2 极限学习机

Huang 等^[20]提出了极限学习机(ELM)的概念,极限学习机通过随机选取输入层权重和隐藏层偏置和最小化损失

函数来求得输出层的权重。ELM 具有学习速率快,泛化能力强的优点。

极限学习机的网络结构如图 4 所示。其中 ω 和 b 分别是隐含层的权重和偏置, β 是输出层的权重。网络结构中隐含层的权重 ω 和偏置 b 通过随机生成得到,并不在进行调整,输出层的权重 β 是唯一需要确定的参数。




图 4 极限学习机网络结构

Fig. 4 Extreme learning machine network structure

假设输入样本为 (X, Y) , X 表示数据:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1d} \\ x_{21} & x_{22} & \dots & x_{2d} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nd} \end{bmatrix} \quad (5)$$

维度为 $n \times d$, 其中 n 为样本数, d 为特征数目。 Y 为标签, 维度为 $n \times t$:

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{bmatrix} = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1t} \\ y_{21} & y_{22} & \dots & y_{2t} \\ \dots & \dots & \dots & \dots \\ y_{n1} & y_{n2} & \dots & y_{nt} \end{bmatrix} \quad (6)$$

假设隐含层神经元数目为 m , 可得 $d \times m$ 维的权重矩阵:

$$w = [w_1 \ w_2 \ \dots \ w_m] = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1m} \\ w_{21} & w_{22} & \dots & w_{2m} \\ \dots & \dots & \dots & \dots \\ w_{d1} & w_{d2} & \dots & w_{dm} \end{bmatrix} \quad (7)$$

假设隐含层的输出为 H , 可得其表达式:

$$H = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \dots & g(\omega_m x_1 + b_m) \\ g(\omega_1 x_2 + b_1) & \dots & g(\omega_m x_2 + b_m) \\ \dots & \dots & \dots \\ g(\omega_1 x_n + b_1) & \dots & g(\omega_m x_n + b_m) \end{bmatrix} \quad (8)$$

式中: $g(\cdot)$ 为激活函数。

由上述表达式计算得到 β :

$$\beta = H^+ Y \quad (9)$$

式中: H^+ 为矩阵 M-P 广义逆。

3.3 秃鹰搜索算法

ELM 在训练时会随机初始化输入层到隐藏层之间的

权重和隐含层偏置,这可能导致模型的泛化性能存在不确定性,对故障诊断结果产生影响,引入 BES 对 ELM 隐含层的权重和偏置进行寻优。

秃鹰搜索算法^[21](BES)是一种新型群优化算法,由马来西亚学者 Alsattar 等提出。其灵感来源于自然界中秃鹰搜寻和捕食鱼类的行为,共分为选择、搜索和俯冲 3 个阶段,秃鹰狩猎过程如图 5 所示。

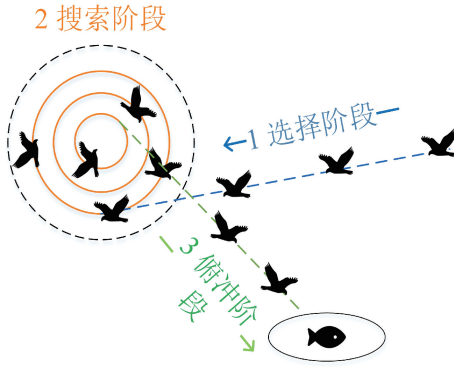


图 5 秃鹰捕猎过程

Fig. 5 Bald eagle hunting process

在选择阶段,秃鹰会根据区域的猎物数量来确定最佳捕食范围,之后便在该区域进行搜索。这个阶段的位置更新可以描述为:

$$P_{i,new} = P_{best} + \alpha \times r(P_{mean} - P_i) \quad (10)$$

式中: P_i 表示第 i 只秃鹰所在位置; $P_{i,new}$ 表示第 i 只秃鹰的最新位置; P_{best} 表示秃鹰当前的最佳位置; P_{mean} 是距上次搜索后的平均位置。 α 为位置变化控制参数; r 是介于 0 到 1 的随机数。

在第一阶段的基础上,秃鹰在特定区间内盘旋飞行,不断寻找猎物。这里采用极坐标的形式对二阶段秃鹰的位置进行描述,具体形式如下:

$$P_{i,new} = P_i + y(i) \times (P_i - P_{i+1}) + x(i) \times (P_i - P_{mean}) \quad (11)$$

$$x(i) = \frac{xr(i)}{\max(|xr|)} y(i) = \frac{yr(i)}{\max(|yr|)} \quad (12)$$

$$\begin{cases} xr(i) = r(i) \times \sin(\theta(i)) \\ yr(i) = r(i) \times \cos(\theta(i)) \end{cases} \quad (13)$$

$$\begin{cases} \theta(i) = a \times \pi \times rand \\ r(i) = \theta(i) + R \times rand \end{cases} \quad (14)$$

式中: $x(i)$ 、 $y(i)$ 表示秃鹰在极坐标系中的坐标位置,其大小位于 -1 和 1 之间; P_{i+1} 表示第 i 只秃鹰的下一位置; a 、 R 分别为螺旋线相关参数; $\theta(i)$ 为螺旋方程极角, $r(i)$ 为极径。

在俯冲阶段,秃鹰从第二阶段搜索到的最佳位置俯冲向猎物,对这个阶段秃鹰的行为表示如下:

$$\begin{cases} \delta_x = x1(i) \times (P_i - c_1 \times P_{mean}) \\ \delta_y = y1(i) \times (P_i - c_2 \times P_{best}) \end{cases} \quad (15)$$

$$P_{i,new} = rand \times P_{best} + \delta_x + \delta_y \quad (16)$$

式中: c_1 、 c_2 为秃鹰向最佳与中心位置的运动强度,介于 1 到 2 之间。

3.4 模型诊断流程

基于 CNN-BES-ELM 的航空发动机气路故障诊断流程如图 6 所示,具体操作如下^[22]:

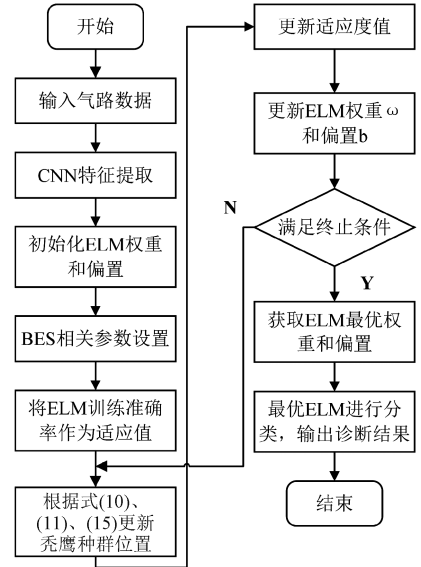


图 6 基于 CNN-BES-ELM 模型诊断流程

Fig. 6 Diagnostic process based on CNN-BES-ELM model

步骤 1) 气路数据预处理,划分训练集和测试集。

步骤 2) CNN 对输入数据进行特征提取,并将所提取到的特征输入到 ELM 中。

步骤 3) 初始化极限学习神经网络结构。

步骤 4) 根据气路数据特征,设置 BES 中的种群数量、最大迭代次数等算法相关参数。

步骤 5) 由式(10)、(11)、(15)计算得到秃鹰的最新位置和新的适应度值并更新位置和适应度。

步骤 6) ELM 在训练过程中,适应度值随着秃鹰位置的更新而改变,不断迭代更新得到更优的适应度以及 ELM 隐含层的权重和偏置。

步骤 7) 迭代达到终止条件时,循环结束,得到最优的 ω 和 b ; 若不满足条件,则继续进行迭代。

步骤 8) 由迭代得到的最优 ω 和 b 的和搭建 ELM,对 CNN 提取的特征进行分类,实现故障诊断。

4 仿真实验及结果分析

4.1 仿真实验评价指标

对故障诊断模型的优劣进行评价需要从多角度出发,综合多种因素。选择准确率、精确率、召回率和 F1 分数作为本文故障诊断模型的评价指标,因为它们能够全面反映模型的整体性能、正类预测的准确性、找出所有正类样本的能力以及精确性和召回率的平衡性。这些指标能够综合评

估模型的优劣。准确率、精确率、召回率和 F1 分数的计算公式如下：

$$\left\{ \begin{aligned} \text{准确率} &= \frac{TP + TN}{TP + FP + TN + FN} \\ \text{精确率} &= \frac{TP}{TP + FP} \\ \text{召回率} &= \frac{TP}{TP + FN} \\ \text{F1} &= \frac{2 \times TP}{2 \times TP + FP + FN} \end{aligned} \right. \quad (17)$$

式中: TP 为真正例, FP 为假正例, TN 为真负例, FN 为假负例。

4.2 CNN-BES-ELM 模型建立

为了验证模型中 CNN 层数取值、训练集数据占比对模型故障诊断结果的影响。现对 CNN 卷积层和池化层数目、训练集占比的具体取值进行实验分析。

1) CNN 网络结构确定

CNN 的层数确定很重要,当网络层数过少时,浅层的网络无法充分提取发动机气路数据中的信息,影响诊断的准确率;当网络层数过多时,容易产生过拟合现象。同时由于网络结构变得复杂,训练时间会增加。现就不同数目的卷积-池化层对进行实验,在其余实验条件不变的前提下重复进行 10 次实验取平均值,得到实验结果如表 3 所示。

表 3 不同数目卷积层和池化层实验结果
Table 3 Experimental results with different number of convolutional and pooling layers

卷积-池化对数目	准确率/%	训练时间/s
1	92.32	29.24
2	95.84	33.48
3	97.44	38.53
4	96.34	45.99
5	96.28	48.25

由表 3 可得,选择 3 个卷积-池化对时,模型的准确率最高。尽管较少的卷积层-池化对数可以缩短训练时间,但会降低准确率;若层数过多,容易导致过拟合,准确率下降,训练时间增加。因此,选择了包含 3 个卷积-池化对的 CNN 结构。

2) 训练集占比对诊断模型影响

为探究输入数据训练集大小对故障诊断模型准确率的影响,设置训练集占比分别为 0.5、0.6、0.7 和 0.8 的 4 个类别进行实验,得到实验结果如图 7 所示。

由图 7 可得,模型的诊断准确率随着训练集数据占比的提高而提高,符合机器学习的一般规律。当训练集占比过大时,模型将有更多的数据用于学习,但这可能导致模型变得复杂,模型的泛化能力较差,出现过拟合现象;当训练集占比过小时,模型没有足够的学习数据来学习数据的内在规

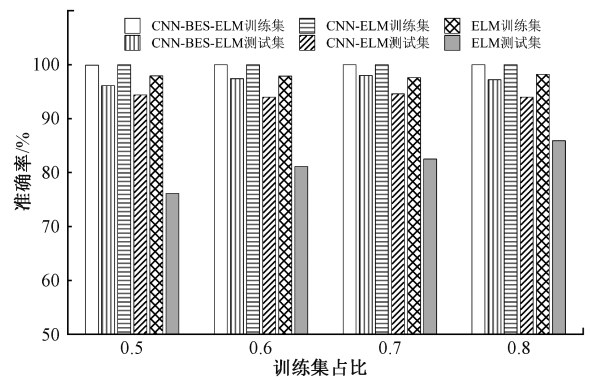


图 7 不同训练集占比的诊断准确率

Fig. 7 Diagnostic accuracy for different training set shares

律和特征,出现欠拟合现象。

综上所述,为了确保模型既能充分学习数据的内在规律,又能有效地避免过拟合,最终取训练集占比为 0.6。

3) 消融实验

消融实验在深度学习领域被广泛采用。其核心操作是移除或替换模型中的关键组件,然后观察模型性能的变化。并以此有效地评估模型各个部分对整体性能的具体影响。在不改变其余实验参数的情况下,分别移除 BES、ELM 和 CNN。考虑到在故障诊断过程中模型的诊断结果可能存在一定波动,为了提高实验结果的可信度,文中的结果最终取值为单独 10 次实验结果的平均值,如表 4 所示。

表 4 各类诊断模型诊断准确率

Table 4 Diagnostic accuracy of various diagnostic models

诊断模型	准确率	精确率	召回率	F1 分数
ELM	90.45	92.56	90.09	91.30
CNN	92.40	93.23	92.39	92.81
CNN-ELM	95.10	95.32	95.19	95.20
CNN-BES-ELM	97.80	97.89	97.79	97.84

由表 4 可得,在各类方法中,CNN-BES-ELM 的各项指标均达到最优,能够精准地识别出航空发动机气路的各类故障模式。

此外,将本文提出的方法与深度置信网络^[23](deep belief networks, DBN)和堆叠自编码器^[24](stacked auto-encoders, SAE)这些主流深度学习模型进行比较,每个模型均独立进行 10 次实验,所得结果取平均值,具体结果如表 5 所示。

4) 模型抗噪测试

航空发动机传感器数据会受到诸如环境条件和机器运行等多种相关因素的影响,通常会伴随着各种不同的噪声。为了使研究方法能够更适配真实发动机情况,在故障数据中添加噪声来模拟真实传感器采集的数据。

表 5 各诊断模型平均实验结果

Table 5 Average experimental results for each diagnostic model %

诊断模型	准确率	精确率	召回率	F1 分数
DBN	92.40	93.23	92.39	92.81
SAE	94.04	94.72	94.03	94.37
CNN-BES-ELM	97.80	97.89	97.79	97.84

参考我国传感器测量误差和数据传输实际情况,为了分析 CNN-BES-ELM 诊断模型在噪声下的性能,在航空发动机气路数据中添加强度为 3% 的随机噪声、信噪比为 15 的高斯白噪声和噪声密度为 0.01 的椒盐噪声。分别得到 3 种噪声下的诊断结果准确率,结果如图 8 所示。




图 8 不同种类噪声各方法准确率对比

Fig. 8 Comparison of the accuracy of each method for different types of noise

由图 8 可得,在不同种类噪声的影响下,每种方法的准确率均有不同程度的下降。但是相对比之下,CNN-BES-ELM 下降程度最小,且诊断准确率仍高于 90%,证明其具有较强的抗噪能力,适用于航空发动机的气路故障诊断。

5 结 论

文章提出了一种基于 CNN-BES-ELM 的航空发动机气路故障诊断模型,文章深入研究了 CNN 中卷积层和池化层数目的设置、训练集占比的分配以及不同种类噪声对 CNN-BES-ELM 故障诊断模型性能的影响。通过详尽的实验分析,得出以下结论:

CNN-BES-ELM 模型在 3 个卷积-池化对、训练集数据占比为 0.6 的情况下,取得较好的故障诊断效果。相较于 CNN-ELM、CNN 和 ELM 等模型,CNN-BES-ELM 模型不仅具有更出色的泛化性能,而且在面对不同种类的噪声干扰时表现出了更强的鲁棒性和抗噪能力。

在航空发动机的气路故障诊断中,CNN-BES-ELM 已经表现出较高的准确率,但仍存在一些困难需要解决,比如

当发动机的故障特征耦合程度较高时或遇到某些较为复杂的情况时,模型的诊断准确率仍有待进一步提高。

参考文献

- [1] 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 J Q, WANG Q H, LU F. Research status and prospect of gas path fault diagnosis for aeroengine[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2020, 52(4): 507-522.
- [2] 李一波,张光明,蒋丽英. 航空发动机气路故障诊断技术研究现状[J]. 燃气轮机技术, 2009, 22(3): 10-15.
LI Y B, ZHANG G M, JIANG L Y. Current status of aero-engine gas circuit fault diagnosis technology[J]. Gas Turbine Technology, 2009, 22(3): 10-15.
- [3] 崔建国,李勇,王景霖,等. 航空发动机的 IGWO-KELM 故障诊断方法[J]. 机械设计与制造, 2023(12): 36-40.
CUI J G, LI Y, WANG J L, et al. IGWO-KELM fault diagnosis method for aircraft engines [J]. Mechanical Design and Manufacturing, 2023 (12): 36-40.
- [4] 刘海瑞,武宪威,李鹏,等. 基于 APSO-LSSVM 的航空发动机轴承故障诊断及寿命预测[J]. 测控技术, 2024, 43(1): 70-76.
LIU H R, WU X W, LI P, et al. Aero-engine bearing fault diagnosis and life prediction based on APSO-LSSVM[J]. Measurement and Control Technology, 2024, 43(1): 70-76.
- [5] 朱海龙,贾如侠,张亮,等. 基于证据推理和置信规则库的涡扇发动机故障预测[J]. 系统仿真学报, 2022, 34(9): 2074-2086.
ZHU H L, JIA R X, ZHANG L, et al. Turbofan engine fault prediction based on evidential reasoning and confidence rule base [J]. Journal of System Simulation, 2022, 34(9): 2074-2086.
- [6] 吕卫民,孙晨峰,任立坤,等. 一种基于 TCN-LGBM 的航空发动机气路故障诊断方法[J]. 兵工学报, 2024, 45(1): 253-263.
LYU W M, SUN CH F, REN L K, et al. An aero-engine airway fault diagnosis method based on TCN-LGBM[J]. Journal of Military Engineering, 2024, 45(1): 253-263.
- [7] 王月,赵明航,刘雪云,等. 基于孪生减元注意力网络的航空发动机故障诊断[J]. 航空动力学报, 2023, 38(7): 1784-1792.
WANG Y, ZHAO M H, LIU X Y, et al. Aero-engine fault diagnosis based on twin reduced element attention network[J]. Journal of Aerospace Dynamics, 2023,

- 38(7): 1784-1792.
- [8] BENYOUNES A, HAFIFA A, KOUZOU A, et al. Gas turbine modeling using adaptive fuzzy neural network approach based on measured data classification [J]. Mathematics-in-Industry Case Studies, 2017, 7: 1-14.
- [9] ZHAO J, PENG Y H, XIN N. An aero-engine gas path fault diagnosis method based on OPABC-BP[C]. 2021 IEEE International Conference on Prognostics and Health Management(ICPHM), 2021: 1-6.
- [10] ZHONG SH SH, FU S, LIN L. A novel gas turbine fault diagnosis method based on transfer learning with CNN[J]. Measurement, 2019, 137: 435-453.
- [11] CHEN Z K, YUAN X, SUN M Y, et al. A hybrid deep computation model for feature learning on aero-engine data: Applications to fault detection [J]. Applied Mathematical Modelling, 2020, 83: 487-496.
- [12] ZHOU D J, YAO Q B, WU H, et al. Fault diagnosis of gas turbine based on partly interpretable convolutional neural networks[J]. Energy, 2020, 200: 117467.
- [13] TAHAN M, TSOUTSANIS E, MUHAMMAD M, et al. Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines: A review[J]. Applied Energy, 2017, 198: 122-144.
- [14] 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 SH CH, CHEN M, HU J T, et al. Advances in gas circuit troubleshooting of aero-gas turbine engines [J]. Aero Engine, 2022, 48(2): 33-49.
- [15] 许梦阳, 黄金泉, 鲁峰. 航空发动机气路故障诊断的 SANNWA-PF 算法 [J]. 航空动力学报, 2017, 32(10): 2516-2525.
- XU M Y, HUANG J Q, LU F. SANNWA-PF algorithm for aero-engine airway fault diagnosis [J]. Journal of Aerospace Dynamics, 2017, 32(10): 2516-2525.
- [16] ZHANG K X, LIN B, CHEN J X, et al. Aero-enginesurge fault diagnosis using deep neural network[J]. Computing Systems Science Engineering, 2022, 42(1): 351-360.
- [17] 徐卓飞, 李旭东, 张婵婵, 等. 基于孪生网络的小样本滚动轴承故障诊断研究[J]. 仪器仪表学报, 2022, 43(10): 241-251.
- XU ZH F, LI X D, ZHANG CH CH, et al. Twin network-based fault diagnosis of rolling bearings with small samples[J]. Journal of Instrumentation, 2022, 43(10): 241-251.
- [18] 雷春丽, 夏奔锋, 薛林林, 等. 小样本下自校正卷积神经网络的滚动轴承故障识别方法[J]. 仪器仪表学报, 2022, 43(9): 122-130.
- LEI CH L, XIA B F, XUE L L, et al. Self-correcting convolutional neural network for rolling bearing fault identification in small samples [J]. Journal of Instrumentation, 2022, 43(9): 122-130.
- [19] 于波, 李建成, 陈先瑞, 等. 基于 CNN 的轴承变工况故障识别系统[J]. 电子测量技术, 2022, 45(19): 25-29.
- YU B, LI J CH, CHEN X R, et al. CNN-based fault identification system for bearings with variable operating conditions [J]. Electronic Measurement Technology, 2022, 45(19): 25-29.
- [20] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]. 2004 IEEE International Joint Conference on Neural Networks, 2004: 985-990.
- [21] ALSATTAR H A, ZAIDAN A, ZAIDAN B. Novel meta-heuristic bald eagle search optimisation algorithm [J]. Artificial Intelligence Review, 2020, 53: 2237-2264.
- [22] 王俊, 席芳, 周川, 等. 基于 BES-ELM 的风电机组故障诊断[J]. 排灌机械工程学报, 2023, 41(10): 1023-1029.
- WANG J, XI F, ZHOU CH, et al. Wind turbine fault diagnostic model based on BES-ELM [J]. Journal of Drainage and Irrigation Machinery Engineering (JDIME), 2023, 41(10): 1023-1029.
- [23] 张朝龙, 何怡刚, 杜博伦. 基于 DBN 特征提取的模拟电路早期故障诊断方法[J]. 仪器仪表学报, 2019, 40(10): 112-119.
- ZHANG CH L, HE Y G, DU B L. An early fault diagnosis method for analog circuits based on DBN feature extraction [J]. Journal of Instrumentation, 2019, 40(10): 112-119.
- [24] 洪骥宇, 王华伟, 车畅畅, 等. 改进降噪自编码的航空发动机气路故障诊断[J]. 振动. 测试与诊断, 2019, 39(3): 603-610.
- HONG J Y, WANG H W, CHE CH CH, et al. Improved noise reduction self-coding for aero-engine airway fault diagnosis [J]. Vibration. Test and Diagnosis, 2019, 39(3): 603-610.

作者简介

戴郎杰, 硕士研究生, 主要研究方向为航空发动机故障诊断。

E-mail: dailangjie2000@163.com

蔡开龙(通信作者), 博士, 副教授, 主要研究方向为航空发动机控制、状态监控与故障诊断、航空测试与维修。

E-mail: 70692@nchu.edu.cn