

文章编号: 1000-8055(2023)07-1784-09

doi: 10.13224/j.cnki.jasp.20210195

基于孪生减元注意力网络的航空发动机故障诊断

王 月¹, 赵明航², 刘雪云², 林 琳¹, 钟诗胜^{1,2}

(1. 哈尔滨工业大学 机电工程学院, 哈尔滨 150001;
2. 哈尔滨工业大学(威海) 海洋工程学院, 山东 威海 264209)

摘 要: 针对传统故障诊断方法在故障样本缺乏条件下容易遭遇过拟合, 以及强噪声条件下微弱故障特征难以提取的问题, 提出了一种基于孪生减元注意力网络的航空发动机故障诊断方法。根据孪生神经网络的原理, 将训练样本集中的样本随机两两配对, 使输入从样本变为样本对, 实现样本量的扩增。在特征提取模块引入减元注意力机制。其中, 注意力机制能够通过全局扫描, 快速找到有用特征, 并且抑制冗余特征, 这与航空发动机微弱气路故障特征被噪声所淹没的情况吻合良好; 减元操作可以降低模型的参数量, 缓解过拟合现象。研究结果表明: 该方法在某航空公司 CFM56-5B/7B 系列发动机的真实监测数据上取得了 88.39% 的平均准确率。

关 键 词: 故障诊断; 孪生神经网络; 减元注意力; 涡扇发动机; 小样本

中图分类号: V263.6

文献标志码: A

Aero-engine fault diagnosis based on Siamese reduced-neuron attention networks

WANG Yue¹, ZHAO Minghang², LIU Xueyun², LIN Lin¹, ZHONG Shisheng^{1,2}

(1. School of Mechatronics Engineering, Harbin Institute of Technology, Harbin 150001, China;
2. School of Ocean Engineering,
Harbin Institute of Technology at Weihai, Weihai Shandong 264209, China)

Abstract: In view of the problems that traditional fault diagnosis methods are prone to over-fitting under the condition of insufficient fault samples, and the weak fault features are difficult to be extracted under strong noise conditions, an aero-engine fault diagnosis method based on Siamese reduced-neuron attention networks was proposed. According to the principle of Siamese neural network, pairwise coupling of the samples in the training dataset was conducted, so that the input was changed from samples to sample pairs, and the diversity of input was improved. A reduced-neuron attention mechanism was integrated into the feature extraction module. Among them, the attention mechanism can quickly find useful features through global scanning, and suppress redundant features, which was in good agreement with the situation where the weak gas path fault features of aero-engines were submerged by noise; the reduced-neuron operation can reduce the amount of parameters and alleviate overfitting. The results show that this method achieves an average accuracy of 88.39% on the real monitoring data of CMF56-5B/7B series engines of an airline.

Keywords: fault diagnosis; siamese neural network; reduced-neuron attention; turbofan engine; limited samples

收稿日期: 2021-04-26

基金项目: 国家自然科学基金联合基金(U1933202); 山东省自然科学基金(ZR2020QE156)

作者简介: 王月(1997—), 女, 工程师, 硕士, 研究方向为航空发动机健康管理与故障诊断。

通信作者: 赵明航(1991—), 男, 副教授, 博士, 研究方向为航空发动机状态监测与智能维护。E-mail: zhaomh@hit.edu.cn

引用格式: 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 Yue, ZHAO Minghang, LIU Xueyun, et al. Aero-engine fault diagnosis based on Siamese reduced-neuron attention networks[J]. Journal of Aerospace Power, 2023, 38(7): 1784-1792.

航空发动机状态的优劣是影响飞机飞行安全和出勤率的重要因素^[1]。而航空发动机是一种结构高度复杂的动力装备^[2],在飞机飞行过程中,航空发动机在高噪声、强振动的极端恶劣工作环境中长时间持续工作,不可避免会产生某些故障^[3-5];而故障一旦发生,就可能会引发巨大的经济损失和人员伤亡。因此,研究准确的故障诊断方法,对航空发动机进行全面的故障诊断来保障飞机正常飞行,就具有重要的工程价值。

随着计算机科学和智能信息处理技术的发展,形成了众多故障诊断技术,取得了大量的研究成果^[6-7]。数据驱动的故障诊断方法不需要考虑机械设备的物理结构,只需根据传感器采集到的数据,训练机器学习模型,就可以进行故障诊断^[8-10]。卷积神经网络^[11-12]利用卷积层和池化层提取信号含有的重要特征,最后使用全连接层对设备是否发生故障进行判断;集成神经网络^[13]能够将振动信息和油液信息融合并在航空发动机轴承故障诊断中应用;自组织映射网络^[14]能够在无监督的模式下对故障现象进行分类;但以上故障诊断方法都需要大量数据进行模型训练,才可以得到好的故障诊断结果,而航空发动机部分气路故障数据很难获得,能搜集到的状态数据极其少,对于故障类型多、样本数据少情况下的故障诊断,直接采用深度学习模型无法提取到准确的特征,不能得到较高的诊断准确率。

近年来,部分学者已经开展了小样本下诊断方法的研究^[15-16]。例如,将深度自编码器和支持向量机结合,利用深度自动编码器进行大量数据模型的训练和迁移,最终使用支持向量机实现小样本分类^[17];基于基尼系数获得分类决策树,构建故障诊断规则,最后实现小样本故障诊断^[18];建立深度置信网络,通过添加新的隐藏层,强化特征提取能力,提高故障诊断正确率^[19];基于深度自适应卷积网络的故障诊断方法通过自适应损失功能为所有类别分配不同的错误分类成本,并在训练过程中不断更新^[20]。但是上述故障诊断方法并没有考虑到航空发动机运行环境中噪声干扰繁多、微弱特征很难提取的问题。

因此,面向小样本和强噪声下的航空发动机故障诊断,本文提出了一种基于孪生减元注意力网络(siemese reduced-neuron attention networks, SRAN)的航空发动机故障诊断方法。通过将孪生神经网络的输入由样本变成样本对,增加了训

练样本规模;孪生神经网络的特征提取模块中引入减元注意力机制,对各个特征赋予不同的权重,强化模型在强噪声干扰环境中的特征提取能力,同时通过减元操作降低模型复杂度,在一定程度上缓解神经元数量多带来的过拟合现象。采用某航空公司 CFM56-5B/7B 系列发动机的真实监测数据进行实验,与 k 近邻、多层感知机、孪生多层感知机、孪生注意力网络进行对比,结果表明:该方法能够有效地提取出强噪声环境中航空发动机小样本数据集所蕴含的故障特征,提升小样本数据集上的故障诊断正确率,初步验证了其实际工程应用的潜力。

1 孪生减元注意力网络

本部分首先分别介绍了孪生神经网络和减元注意力机制的基本原理,然后对 SRAN 算法的整体流程进行了描述。

1.1 孪生神经网络

孪生神经网络是由 Bromley 等^[21]所提出的一种特征相似性度量网络,被广泛应用于相似样本的分析,适用于类别繁多、每个类别的样本数量少情况下的识别、分类等情形^[22-23]。

在孪生神经网络中,输入数据是样本之间两两随机配对生成的同类样本对和不同类样本对及其对应的标签,标签设定规则为:样本对属于同类时,标签为 1;样本对属于不同类时,标签为 0。经过特征提取和相似度计算两个阶段的运算,输出特征是样本之间的距离,用于表示样本之间的相似程度。孪生神经网络的基础结构如图 1 所示。




图1 孪生神经网络结构图

Fig. 1 Architecture of a siamese neural network

如图 1 所示,在样本库中随机选取一对样本 X_1 和 X_2 作为输入数据,输入孪生神经网络中的特征提取模块(即两个神经网络模块)中。特征提取模块含有左右两个相同的神经网络模块,这两个

神经网络模块有共享参数 W 和偏置 b , 分别将两个输入样本 X_1 和 X_2 映射到新的相同特征空间中, 得到两个输入样本 X_1 和 X_2 新的特征向量表示 $G_W(X_1)$ 和 $G_W(X_2)$; 在相似度计算模块中, 计算在新的相同特征空间中两个特征向量 $G_W(X_1)$ 和 $G_W(X_2)$ 之间的距离, 来表示两个输入样本之间的相似度, 且两样本距离越大, 相似度越低; 距离越小, 两者就越为相似。

孪生神经网络根据在同一特征空间中距离的相似性度量, 来判别样本是否归属同一类别。在孪生神经网络的训练过程中, 为了减小同类样本之间的损失值, 增大不同类样本之间的损失值, 所采用的损失函数是对比损失函数^[24]。

对比损失函数的计算方程式如下:

$$L(W, (Y, X_1, X_2)) = \frac{1}{2N_{\text{size}}} \sum_{n=1}^{N_{\text{size}}} Y D_W^2 + (1 - Y) \max(m - D_W, 0)^2 \quad (1)$$

式中 W 表示孪生神经网络中特征提取模块的共享参数; Y 为两个样本是否为同类型的标签, $Y=1$ 代表两个样本为同一类别的样本, $Y=0$ 则代表两样本为不同类别的样本; X_1 和 X_2 分别为孪生神经网络输入的一对样本对中的两个样本; N_{size} 为 batch size 中样本对的个数; n 是样本对的序号; $D_W(X_1, X_2)$ 代表两个样本特征向量 $G_W(X_1)$ 和 $G_W(X_2)$ 的距离; m 为设定的阈值表示距离最大值, 在计算损失值时只考虑不相似样本距离在 $0 \sim m$ 之间的。当不相似样本距离超过 m 时, 即当不相似的样本离得很远, 其损失值应该是很低的, 因此把其损失值看作为 0; 而对于相似的样本反而离得很远时, 需要增加其损失值, 从而不断优化模型参数。

不难看出, 当 $Y=1$ 时, 即样本对属于同一类别时, 对比损失函数只剩下式(1)里的前半部分, 如下所示:

$$L_s = \frac{1}{2N_{\text{size}}} \sum_{n=1}^{N_{\text{size}}} Y D_W^2 \quad (2)$$

即原本属于相同类别的两个样本, 如果在特征空间的距离较小, 则说明当前的模型参数较好, 此时损失值应该较小; 如果在特征空间的距离较大, 则说明当前的模型参数不够好, 此时损失值较大。

当 $Y=0$, 即样本对分别隶属不同的类别时, 损失函数为公式(1)的后半部分, 如下所示:

$$L_d = \frac{1}{2N_{\text{size}}} \sum_{n=1}^{N_{\text{size}}} (1 - Y) \max(m - D_W, 0)^2 \quad (3)$$

即当样本对中两个样本为不同类时, 如果在特征空间的距离较大, 则说明当前的模型参数较好, 损失值较小; 如果在特征空间的距离反而小的话, 则说明当前的模型参数不够好, 损失值较大。

孪生神经网络是利用从数据中学习的相似性度量, 去判断两个样本是否属于相同类别, 而不是让模型直接学习分类; 因此, 孪生神经网络不需要大量数据来进行参数训练, 降低了对样本数量的要求; 同时, 孪生神经网络的输入从样本变成了样本对, 又变相地增加了整个数据集的规模。因此, 对于小样本的情况, 孪生神经网络是有着良好适用性的。

1.2 减元注意力

本文所构建的 SRAN 是对孪生神经网络的特征提取部分进行了改进, 在用于特征提取的神经网络模块中引入减元注意力机制, 来提高深度学习模型在强噪声环境中的微弱故障特征提取能力。

在传统神经网络中, 默认每一个神经元对应的权值是固定的, 但是在实际过程中, 处于强噪声环境的小样本数据集中强噪声干扰严重, 微弱特征难以提取。注意力机制就是在深度学习模型中嵌入的一种特殊结构, 用来自动学习和计算输入数据对输出数据的贡献大小^[25], 即通过学习训练, 让网络学习一层新的权重赋予各个特征, 将数据中关键的特征标识出来。通过注意力机制, 使模型能够重点学习重要信息, 忽略次要信息; 通过减元操作, 减少神经元个数, 减小模型复杂度, 加快训练速度, 同时减轻训练难度。引入减元注意力机制后的残差模块(residual module with reduced-neuron attention mechanism, RM-RNAM)如图2所示, 其中 N 表示神经网络层的特征维度, p 表示减元系数(p 为整数且 $p \geq 2$)。

在孪生神经网络的特征提取模块, 所采用的神经网络是多层感知机, 在多层感知机的每一层神经网络层之间引入减元注意力机制。在减元注意力机制中, 神经元特征进入减元注意力模型后, 首先是一层用于提取特征之间关联关系和降低模型复杂度的、对特征进行降维操作的全连接层, 经过批标准化层和 RELU 层的处理计算, 之后是用于还原特征维度的、对特征进行升维的全连接层, 并经过批标准化层的处理, 用 Sigmoid 激活函数对特征权重进行归一化处理, 并对每一个神经元




图2 引入减元注意力机制的残差模块(RM-RNAM)

Fig. 2 Residual module with reduced-neuron attention mechanism (RM-RNAM)

特征进行权重分配,最终得到每一个神经元特征的权重。最后进行特征和各自权重的点乘计算,将每一个神经元特征乘上其对应的权重,将该乘积作为减元注意力机制的输出特征向量。

在特征提取部分引入减元注意力机制就是给每一个特征赋予不同的权重,将特征按照不同的信息量价值排序,含信息量越大的特征赋予的权重越高,通过该过程降低噪声干扰对特征的影响,保留更多分类需要的关键特征信息,减小在小样本数据集中强噪声干扰对模型特征提取能力的负面影响;在网络模型中引入注意力机制会增加网络层深度,增加模型复杂度,对于小样本数据集而言,模型过于复杂会导致过拟合现象,使模型泛化能力差,通过引入减元操作缓解深度神经网络在小样本数据集中由于网络模型复杂、神经元数量多引起的过拟合现象,提高模型的泛化能力。

减元注意力机制可以被嵌入到任意一个深度神经网络的任意部位,通过对各个神经元施加不同权值的方式,对各维特征进行奖惩,减小噪声冗余的影响,提高特征的表示能力,进而提高模型的特征学习能力,并且在一定范围内减小深度模型的复杂程度,提高模型的泛化能力。同时,在基于反向传播算法的训练过程中,采用跨层恒等结构以利于优化神经网络模型,减轻由于网络层数加深所带来的模型参数训练困难的问题。

1.3 孪生减元注意力网络

如图3所示,在孪生减元注意力网络中,首先需要建立孪生神经网络,由于孪生神经网络的输入是样本对,需要将训练样本集通过样本之间的两两随机配对生成同类样本对和不同类样本对及其对应的标签;接着,将多层感知机作为孪生神经网络特征提取模块的基础神经网络,并在每层神经网络层之间中引入减元注意力机制,使特征提取模块的最终输出为各个特征与其对应权重的乘积,




图3 孪生减元注意力网络结构图

Fig. 3 Architecture of the siamese reduced-neuron attention network

将该乘积作为特征向量输入相似度量模块中;换言之,将生成的样本对中的两个样本分别输入到孪生神经网络中左右两个特征提取模块中进行特征提取,得到相同特征空间中各自不同的特征向量;最后,通过孪生神经网络中相似度量模块计算两样本特征向量的距离得到两样本之间的相似度量,作为判断该样本对中两个样本是否为同类的依据。

相似度量是用于计算样本对中两个不同样本的特征向量之间的距离,来评定两个样本之间相似程度的一种度量。在计算待测样本对的距离时,采用的是欧式距离。两样本的距离越小,则样本相似度越高,判定两样本为相同类别;距离越大,则样本相似度越低,判定两样本属于不同类别。

在测试过程中,将待测样本分别与各类型样本生成样本对,输入孪生减元注意力网络中,计算待测样本与各个类型样本的相似度,并进行对比,最后判定该待测样本属于相似度最大的样本

类别。

2 实验验证

为了验证本文构建的 SRAN 的实用性及有效性,采用 CFM56-5B/7B 飞机的航空发动机真实监测数据进行实验测试,将本文构建的 SRAN 模型与传统的模式识别算法,以及较新的深度神经网络算法进行了实验对比,通过测试集准确率、误差曲线和混淆矩阵等评价指标的对比,验证了 SRAN 的有效性。

2.1 实验数据

本文采用 CFM56-5B/7B 飞机的航空发动机数据进行实验验证。实验中,本文选用原始设备制造商(original equipment manufacturer, OEM)数据进行航空发动机故障诊断,选取 OEM 数据中正常状态、进口总温指示(total air-inlet temperature indication, TAT)故障、排气温度指示(exhaust gas temperature indication, EGTI)故障、可调放气阀门(valve blow vent, VBV)故障 4 种航空发动机状态类型。

航空发动机故障数据的基本信息如表 1 所示。其中,在训练集数据样本中,正常状态样本有 60 组,TAT 故障、EGTI 故障、VBV 故障分别各有 15 组,共有 105 组样本进行航空发动机故障诊断;测试集数据样本中正常状态样本有 16 组,TAT 故障、EGTI 故障、VBV 故障分别各有 5 组,共 31 组测试样本进行模型测试。

在航空发动机的气路参数中,OEM 主要使用了排气温度偏差值(deviation exhaust gas temperature, DEGT)、燃油流量偏差值(deviation fuel flow, DFF)、高压转子转速偏差值(deviation high pres-

sure rotor speed, D_{n2})和低压转子转速(low pressure rotor speed, N_1)4 个气路性能参数对气路故障进行判断。因此,本文同样选取 DEGT、DFF、 D_{n2} 、 N_1 这 4 个气路参数作为健康状态指标,每连续 10 个数据为一个输入样本,从而每个输入样本的维度为 40。

表 1 航空发动机故障诊断数据集
Table 1 Aero-engine fault diagnosis set

故障编号	健康状态	训练集样本数量	测试集样本数量
1	正常状态	60	16
2	TAT 故障	15	5
3	EGTI 故障	15	5
4	VBV 故障	15	5

航空发动机原始气路参数存在不同量纲,气路参数之间数据差异大,因此需要对其标准化处理。为了不改变数据的分布,选用 Min-Max 标准化(也称离差标准化)方法,计算公式为

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)} \tag{4}$$

其中 $\min(x)$ 表示 x 的最小值, $\max(x)$ 表示 x 的最大值。通过 Min-Max 标准化方法,将原始数据线性变换后落到 [0, 1] 区间,同时去除量纲,避免因取值范围差别大导致的误差问题。

将数据进行标准化处理后,根据标签生成规则,将训练集数据生成样本对和标签,标签设定规则为:样本对中样本为同类时,标签为 1;样本对中样本为不同类时,标签为 0;将训练集样本共生成 4 组同类样本对和 6 组非同类样本对,如表 2 所示。

表 2 训练集样本对和标签表
Table 2 Training set pair and label

样本 1	样本 2	样本对	样本对标签
正常状态	正常样本	(正常状态, 正常状态)	1
正常状态	VBV 故障	(正常状态, VBV 故障)	0
正常状态	EGTI 故障	(正常状态, EGTI 故障)	0
正常状态	TAT 故障	(正常状态, TAT 故障)	0
VBV 故障	VBV 故障	(VBV 故障, VBV 故障)	1
VBV 故障	EGTI 故障	(VBV 故障, EGTI 故障)	0
VBV 故障	TAT 故障	(VBV 故障, TAT 故障)	0
EGTI 故障	EGTI 故障	(EGTI 故障, EGTI 故障)	1
EGTI 故障	TAT 故障	(EGTI 故障, TAT 故障)	0
TAT 故障	TAT 故障	(TAT 故障, TAT 故障)	1

2.2 实验参数设置

本部分的所有实验都是在配置了 Intel(R) Core(TM) i5-9300H 处理器、8G Random Access Memory(RAM) 的个人计算机上进行的,均采用 Keras 2.2.4 框架进行编程。因为数据量相对较小,未采用显卡(GPU)运算。本文所构建 SRAN 的主干部分包含 3 个全连接层,每个全连接层均含有 64 个神经元,并且在各个全连接层之间嵌入了减元注意力模块。其中,输入数据的维度为 40,经过全连接层、批标准化和 RELU 的计算输入到减元注意力模块中;每个减元注意力模块包含一个降维全连接层和一个升维全连接层,减元系数 p 为 4,降维全连接层的神经元个数为 16,升维全连接层的神经元个数为 64(与原始全连接层神经元个数保持一致),Dropout 系数为 0.1, L2 正则化系数为 0.000 1,输出层的神经元个数为 64。

2.3 实验结果及对比

本文使用 k 折交叉验证($k=5$),对 SRAN 的实验效果进行了验证,并且与 4 种经典方法进行了对比,包括 k 近邻(k -nearest neighbors, KNN)、多层感知机(multi-layer perception network, MLP)、孪生多层感知机(siamese multi-layer perception network, SMLP)和孪生注意力网络(siamese attention network, SAN)。其中, KNN 的近邻数量为 4; MLP 的结构是在 SRAN 中去掉孪生框架、减元注意力模块所得到的; SMLP 的结构是在

SRAN 中去掉减元注意力模块所得到的; SAN 的结构是在 SRAN 中去掉减元操作所得到的;另外, MLP、SMLP 和 SAN 的其他超参数均与 SRAN 保持一致。

本文 5 折交叉验证的结果如图 4 所示,5 次实验的平均准确率及标准差如表 3 所示。首先, SRAN 的平均准确率为 88.39%,相较于 KNN 提高了 23.87%,验证了深层神经网络通过多层非线性映射获取更佳特征的优势。然后, SMLP 的平均准确率为 82.58%,相较于 MLP 提高了 12.90%,验证了孪生神经网络对于小样本数据集的有效性。接着, SRAN 的平均准确率相较于 SMLP 提高了 5.81%,验证了注意力机制在微弱故障特征提取方面的优势。最后, SRAN 的平均准确率相较于 SAN 提高了 16.13%,验证了减元操作能够减轻过拟合,从而提高测试准确率。




图 4 不同模型实验结果对比
Fig. 4 Comparison of experimental results of different models

表 3 不同模型的实验结果对比
Table 3 Comparison of experimental results of different models %

参数	模型				
	KNN	MLP	SMLP	SAN	SRAN
平均准确率	64.52	69.68	82.58	72.26	88.39
标准差	7.63	3.87	4.83	5.98	3.87

值得注意的是, SAN 的参数数量大于 SMLP 和 SRAN,但是 SAN 的测试准确率却低于 SMLP 和 SRAN,从而验证了通过简单地增加原模型的参数数量,是不能提高测试精度的。这是因为参数数量的增加,会导致这些模型遭遇严重的过拟合。减元注意力机制能够在保证特征学习能力的前提下,尽量减少参数数量。

本文所对比的 4 种神经网络在训练过程中的损失曲线如图 5 所示。不难看出,这 4 种方法

在训练集上的损失均降到了较低的水平,相差不大。但是, SRAN 在训练集和测试集上的损失均呈现了较快的下降速度,未出现显著的振荡。不仅如此, SRAN 在测试集上的损失,明显低于其他 3 种方法,验证了 SRAN 不仅能够很好地拟合训练数据,而且能够有效抑制过拟合现象。本文所对比的方法在测试数据上的混淆矩阵如图 6 所示,证实了 SRAN 在各个类别上均取得了较高的正确率。




图 5 训练过程中的损失曲线图

Fig. 5 Loss curves during the training process




图 6 测试数据上的混淆矩阵

Fig. 6 Confusion matrices on the testing dataset

3 结 论

本文开发了一种基于 SRAN 的航空发动机故障诊断方法, 并且在 CFM56-5B/7B 飞机的航空发动机真实监测数据上, 对 SRAN 的有效性进行了验证, 结论如下:

1) 孪生神经网络将人工神经网络的输入数据从样本转变成样本对, 变相地增大了样本规模, 对于小样本故障数据集具备良好的适用性;

2) 在孪生神经网络的特征提取模块中, 引入了减元注意力机制, 为每一维特征施加不同的权重, 使重要信息所对应的特征权重更高, 有效减轻了背景噪声的影响, 从而保留了更多的有用特征信息; 同时, 减元操作在一定程度上减轻了模型复杂程度增大所导致的过拟合现象, 提高了模型在测试数据上的可泛化能力。

参考文献:

- [1] 崔建国, 李国庆, 蒋丽英, 等. 基于深度自编码网络的航空发动机故障诊断[J]. 振动、测试与诊断, 2021, 41(1): 85-89.
CUI Jianguo, LI Guoqing, JIANG Liying, et al. Aero-engine fault diagnosis based on deep self-coding network[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(1): 85-89. (in Chinese)
- [2] LI Huihui, GOU Linfeng, ZHENG Hua, et al. Intelligent fault diagnosis of aeroengine sensors using improved pattern gradient spectrum entropy[J]. International Journal of Aerospace Engineering, 2021, 2021: 8868875.1-8868875.20.
- [3] 李红贤, 韩延, 吴敬涛, 等. 基于ICA包络增强MEMD的滚动轴承故障诊断[J]. 航空动力学报, 2021, 36(2): 405-412.
LI Hongxian, HAN Yan, WU Jingtao, et al. Rolling bearing fault diagnosis based on MEMD with ICA envelop enhancement[J]. Journal of Aerospace Power, 2021, 36(2): 405-412. (in Chinese)
- [4] HUANG Xianghua. Sensor fault diagnosis and reconstruction of engine control system based on autoassociative neural network[J]. Chinese Journal of Aeronautics, 2004, 17(1): 23-27.
- [5] 罗辉. 基于深度特征的民航发动机气路异常检测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
LUO Hui. Research on the gas path anomaly detection of civil aero-engine based on deep features[J]. Harbin: Harbin Institute of Technology, 2020.
- [6] 张建军, 张利, 穆海芳, 等. 基于改进粒子群优化BP网络的发动机故障诊断方法[J]. 农业机械学报, 2011, 42(1): 198-203.
ZHANG Jianjun, ZHANG Li, MU Haifang, et al. Improved BP-neural network of the particle swarm optimization in the research no engine fault diagnosis[J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(1): 198-203. (in Chinese)
- [7] 滕伟, 韩琛, 赵立, 等. 基于改进粒子滤波的重型燃气轮机跳机故障预测[J]. 中国机械工程, 2021, 32(2): 188-194.
TENG Wei, HAN Chen, ZHAO Li, et al. Tripping fault prediction of heavy-duty gas turbines based on improved particle filter[J]. China Mechanical Engineering, 2021, 32(2): 188-194. (in Chinese)
- [8] ZHAO Minghang, ZHONG Shisheng, FU Xuyun, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.
- [9] 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 Mengyang, HUANG Jinquan, LU Feng. SANNWA-PF algorithm of aero-engine gas path fault diagnosis[J]. Journal of Aerospace Power, 2017, 32(10): 2516-2525. (in Chinese)
- [10] 鲜倪军. 基于ABC-BP神经网络的航空发动机故障诊断方法[J]. 装备制造技术, 2018, 281(5): 173-175, 178.
XIAN Nijun. Aero-engine fault diagnosis method based on ABC-BP neural network[J]. Equipment Manufacturing Technology, 2018, 281(5): 173-175, 178. (in Chinese)
- [11] GE Chiru, DU Qian, SUN Weiwei, et al. Deep residual network-based fusion framework for hyperspectral and lidar data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14(1): 2458-2472.
- [12] CHEN Renxiang, HUANG Xin, YANG Lixia. Intelligent fault diagnosis method of planetary gearboxes based on convolution neural network and discrete wavelet transform[J]. Computers in Industry, 2019, 106(1): 48-59.
- [13] 李洪伟, 马中原, 谢镇波. 基于集成神经网络的航空发动机故障诊断研究[J]. 新技术新工艺, 2018, 368(8): 63-66.
LI Hongwei, MA Zhongyuan, XIE Zhenbo. Research on fault diagnosis of aero-engine based on integrated neural network[J]. New Technology & New Process, 2018, 368(8): 63-66. (in Chinese)
- [14] 付宇, 殷逸冰, 冒慧杰, 等. 基于静电监测和神经网络的航发典型故障诊断[J]. 计算机集成制造系统, 2019, 25(11): 2852-2862.
FU Yu, YIN Yibing, MAO Huijie, et al. Fault diagnosis of aero-engine gas path based on electrostatic monitoring and neural network[J]. Computer Integrated Manufacturing Systems, 2019, 25(11): 2852-2862. (in Chinese)
- [15] ZHANG Tianci, CHEN Jinglong, Xie Jingsong, et al. SASLN: Signals augmented self-taught learning networks for mechanical fault diagnosis under small sample condition[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70(1): 1-11.
- [16] YU Ding, MA Liang, MA Jian, et al. A generative adversarial network-based intelligent fault diagnosis method for rotating machinery under small sample size conditions[J]. IEEE Access, 2019, 7(1): 149736-149749.
- [17] 付松, 钟诗胜, 林琳, 等. 基于迁移学习的民航发动机小样本故障诊断[J]. 计算机集成制造系统, 2021, 27(12): 1-19.
FU Song, ZHONG Shisheng, LIN Lin, et al. Gas turbine fault diagnosis method under small sample based on transfer learning[J]. Computer Integrated Manufacturing Systems, 2021, 27(12): 1-19. (in Chinese)
- [18] 庞梦洋, 索中英, 郑万泽, 等. 基于RS-CART决策树的航空发动机小样本故障诊断[J]. 航空动力学报, 2020, 35(7): 1559-1568.
PANG Mengyang, SUO Zhongying, ZHENG Wanze, et al. Small sample fault diagnosis of aeroengine based on RS-CART decision tree[J]. Journal of Aerospace Power, 2020, 35(7): 1559-1568. (in Chinese)
- [19] 陈子兆, 矫文成, 孙慧贤, 等. 基于改进深度置信网络的故障诊断方法[J]. 探测与控制学报, 2020, 42(4): 98-105.
CHEN Zizhao, JIAO Wencheng, SUN Huixian, et al. Fault diagnosis method based on improved deep belief network[J]. Journal of Detection & Control, 2020, 42(4): 98-105. (in Chinese)
- [20] DONG Xun, GAO Hongli, GUO Liang, et al. Deep cost adaptive convolutional network: a classification method for imbalanced me-

- chanical data[J]. IEEE Access, 2020, 8(1): 71486-71496.
- [21] BROMLEY J, BENTZ J W, BOTTOU L, et al. Signature verification using a “siamese” time delay neural network[J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 1993, 7(4): 669-688.
- [22] 王彬文, 吕帅帅, 杨宇. 基于能量图谱和孪生网络的导波损伤诊断方法[J]. 振动、测试与诊断, 2021, 41(1): 182-189, 208. WANG Binwen, LÜ Shuaishuai, YANG Yu. Guided-wave based damage diagnosing method with energy spectrum and siamese network[J]. *Journal of Vibration, Measurement & Diagnosis*, 2021, 41(1): 182-189, 208. (in Chinese)
- [23] 王韵涛, 盛庆华, 郭晨洁, 等. 基于多重孪生网络的表面缺陷识别方法[J]. 计算机应用, 2020, 40(增刊2): 225-229. WANG Yuntao, SHENG Qinghua, GUO Chenjie, et al. Surface defect recognition method based on multiple siamese neural network [J]. *Journal of Computer Applications*, 2020, 40(Suppl.2): 225-229. (in Chinese)
- [24] BUI T, RIBEIRO L, PONTI M, et al. Compact descriptors for sketch-based image retrieval using a triplet loss convolutional neural network[J]. *Computer Vision and Image Understanding*, 2017, 164(1): 27-37.
- [25] 孔子迁, 邓蕾, 汤宝平, 等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法[J]. 仪器仪表学报, 2019, 40(6): 221-227. KONG Ziqian, DENG Lei, TANG Baoping, et al. Fault diagnosis of planetary gearbox based on deep learning with time-frequency fusion and attention mechanism[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(6): 221-227. (in Chinese)

(编辑: 张 雪)