

多源信息融合的核电循泵轴承健康状态增量评估*

刘雪¹, 成玮¹, 周康宁¹, 苟芮侨¹, 陈雪峰¹, 张荣勇², 智一凡²

(1. 西安交通大学机械制造系统工程国家重点实验室 西安, 710049) (2. 中国核电工程有限公司 北京, 100840)

摘要 针对基于深度学习的导轴承健康状态评估模型在增量学习新任务后,几乎彻底遗忘之前学习的内容,导致模型对旧任务评估准确率下降的问题,提出一种多源信息融合的核电循环水泵导轴承健康状态增量评估方法。首先,设计多源信息融合网络,提取反映导轴承健康状态的高维融合特征;其次,通过减小多源信息融合网络的分类损失及蒸馏损失保留新旧任务知识,设计范例管理策略及最邻近均值分类器实现导轴承健康状态增量评估;最后,在核电循环水泵实验台架采集导轴承劣化数据,并对所提方法进行实验验证及对比分析。实验结果表明,所提出方法的准确率可达94%以上。

关键词 核电循环水泵;导轴承;健康状态评估;增量学习

中图分类号 TH133.31;TH17

引言

核电循环水泵作为核电厂中循环水系统的提升设备,主要为核电站汽轮机凝汽器和辅助冷却系统提供冷却水。作为循环水泵中关键旋转部件,泵导轴承位于循环水泵叶轮上方,其单边间隙一旦超过设计要求,可导致叶轮碰损,造成经济损失。目前,核电厂针对循环水泵导轴承健康状态评估手段仍为基于阈值报警的方法,该方法难以精确评估故障初期设备的健康状态,核电运行安全隐患难以及时发现。

近年来,学者们应用深度神经网络评估设备关键部件的健康状态,取得了较好效果。张永等^[1]基于深度学习方法构建双任务框架,实现工业设备的健康状态评估和退化趋势预测联合研究。Chen等^[2]提出一种对抗迁移模型,实现不同段铁路健康状态的迁移评估。尹爱军等^[3]针对现有模型特征信息损失大、泛化能力弱和数据依赖强等问题,提出了一种面向高熵特征数据的变分自编码器轴承健康评估模型。Zhang等^[4]提出一种基于双向长短期记忆网络和多门控混合专家的双重任务模型,实现了航空发动机健康状态评估。上述方法需要提前收集设备劣化数据,离线训练模型。

由于核电循环水泵导轴承需要提前收集劣化数据并训练模型,故此方法难以实现,而具有在线更新

能力的健康状态评估模型更适用于核电企业,具有一定的工程应用前景。文献[5-6]使用新数据在线微调原评估模型,该方法会使模型对旧任务的评估性能大幅下降。增量学习/持续学习可解决上述问题^[7],保证评估模型在新旧任务上均有一定的准确率。受增量学习方法(incremental classifier and representation learning,简称iCaRL)^[8]的启发,笔者通过设计多源融合网络提取高维融合特征,减小多源信息融合网络的分类损失及蒸馏损失,保留新旧任务知识,并设计范例管理策略及最邻近均值分类器,实现核电导轴承健康状态增量评估。

1 多源信息融合网络

残差网络通过为卷积层增加直连边提高信息的传播效率,避免在模型训练中出现网络性能饱和后迅速下降的情况^[9]。考虑固定卷积核难以提取存在于不同敏感频带的多源信号,笔者提出一种多源信息融合网络,如图1所示,通过并联含有不同尺寸卷积核残差网络,实现多源信息的多尺度融合。网络包括4种输入信号:振动加速度、声压、温度和位移。首先,信号经重叠采样方式实现数据增强及样本划分,划分后的样本经过卷积层(convolutional neural network,简称CNN),批归一化层(batch norm,简称BN)以及ReLU激活函数来提取高维特征;其次,

* 国家重点研发计划资助项目(2019YFB1705403);国家自然科学基金资助项目(52105121);王宽诚教育基金会资助项目;中核集团领创项目(J201912021)

收稿日期:2022-04-20;修回日期:2022-06-11




图1 多源信息融合网络

Fig.1 Multi-signal fusion network

高维特征分别经过卷积核为3,5,7的残差块来提取高维多尺度特征;最后,高维多尺度特征经全局最大池化层及全连接层,合并为高维融合特征^[10]。

2 增量学习

2.1 多源信息融合网络训练

蒸馏损失从已训练的模型中提取知识,进而指导新模型训练^[11]。为保存轴承健康状态的新旧知识,笔者设计了组合损失函数及多源信息融合网络训练过程。首先,合并新样本与存储的少量旧范例作为新数据集;其次,存储所有旧范例在旧网络模型的输出;最后,用新数据集训练多源信息融合网络,通过最小化网络的组合损失更新模型参数。

组合损失函数包括蒸馏损失函数和分类损失函数2部分,表达式为

$$l(\Theta) = - \sum_{(x_i, y_i) \in D} \left[\underbrace{\sum_{y=s}^t \delta_{y=y_i} \log g_y(x_i) + \delta_{y \neq y_i} \log(1 - g_y(x_i))}_{\text{分类损失}} + \underbrace{\sum_{y=1}^{s-1} q_i^y \log g_y(x_i) + (1 - q_i^y) \log(1 - g_y(x_i))}_{\text{蒸馏损失}} \right] \quad (1)$$

其中: $\delta_{y=y_i}(\bullet)$ 为示性函数; $g_y(x_i)$ 为待训练模型输出; q_i^y 为旧范例在旧模型上的输出。

蒸馏损失用于在新模型中复现旧范例在原模型的输出^[11],分类损失可提升新样本在新模型中的分类准确率^[12]。

算法1:多源信息融合网络训练

输入 X^s, \dots, X^t //健康状态 s, \dots, t 的训练样本

输入 $P = (P_1, \dots, P_{s-1})$ //前 $s-1$ 个旧样本范例集合

输入 Θ //旧模型参数

//构成组合训练集合:

$$D \leftarrow \bigcup_{y=s, \dots, t} \{(x, y): x \in X^y\} \cup \bigcup_{y=1, \dots, s-1} \{(x, y): x \in P^y\}$$

//固定旧模型参数,存储旧模型网络输出结果

for $y=1, \dots, s-1$ do

$$q_i^y \leftarrow g_y(x_i) \text{ for all } (x_i, \bullet) \in D$$

end for

最小化组合损失函数

2.2 范例管理

因存储空间限制,存储的旧范例限制为固定数量,在下一轮在线训练前需要确定每个旧健康状态可保留的样本数量。假设硬件设备存储样本总量为 K ,新健康状态样本及旧健康状态样本类别为

$$m = \text{round}\left(\frac{K}{t}\right) \quad (2)$$

其中: $\text{round}(\bullet)$ 代表四舍五入。

为存储具有代表性的样本,需要对新样本重要度进行排序,选择最重要的前 m 个新健康状态样本作为范例,样本重要度计算步骤如下。

首先,计算新健康状态样本真实总数为 t ,则每个样本可保留的数量 m 为值 μ ,即

$$\mu = \frac{1}{n} \sum_{x \in X} \varphi(x) \quad (3)$$

其中: $\varphi(\bullet)$ 为多源信息融合网络; $\varphi(x)$ 为新健康状态特征向量; x 为样本; n 为新健康状态样本总数。

其次,依次计算新健康状态每个特征 $\varphi(x)$ 与当前样本集所有特征均值,以及其与样本真实均值 μ 的绝对距离。

最后,将距离最小样本 p_k 加入样本集 P ,即

$$p_k \leftarrow \arg \min \left\| \mu - \frac{1}{k} \left[\varphi(x) + \sum_{j=1}^{k-1} \varphi(p_j) \right] \right\| \quad (4)$$

其中: $\varphi(p_j)$ 为样本集中样本特征向量。

当样本集无样本时,式(4)简化为寻找所有样本中与 μ 差异最小的样本 p_k ,并将其加入样本集

$$p_k \leftarrow \arg \min \left\| \mu - \varphi(x) \right\| \quad (5)$$

上述方法按照与 μ 绝对距离对样本重要度进行排序,重要度高的样本位于样本集前列,新健康状态范例可由样本集中前 m 个新样本组成。此外,还需减少旧健康状态范例数量至 m 个,通过选取旧健康状态前 m 个范例实现。

算法2:新范例管理

输入 $X = \{x_1, \dots, x_n\}$ //新健康状态样本集合

输入 m //新健康状态可存储范例数量

$\varphi: \mathcal{X} \rightarrow \mathbb{R}^d$ //特征向量

for $k=1, \dots, m$ do

$$p_k \leftarrow \arg \min \left\| \mu - \frac{1}{k} \left[\varphi(x) + \sum_{j=1}^{k-1} \varphi(p_j) \right] \right\|$$

end for

$P \leftarrow (p_1, \dots, p_m)$

输出 新健康状态所有范例 P

算法3:旧范例数量变更

输入 m //旧健康状态范例目标数量

输入 $P = (p_1, \dots, p_{|P|})$ //旧健康状态当前范例数量

$P \leftarrow (p_1, \dots, p_m)$ //仅保存前 m 个样本

输出 旧健康状态所有范例 P

2.3 最邻近均值分类器

传统深度模型直接使用神经网络分类,其权重会随输入特征而变化,导致模型输出的分类结果不可控^[5-6]。为了将分类与网络训练过程分离,笔者使用最邻近均值分类器^[13],步骤如下。

1) 对神经网络输出第 y 类健康状态样本特征,得到平均特征向量 μ_y 为

$$\mu_y = \frac{1}{|P_y|} \sum_{p \in P_y} \varphi(p) \quad (6)$$

其中: P_y 为第 y 类健康状态范例集; $\varphi(p)$ 为神经网络

输出的范例特征。

2) 用绝对距离区分样本类别,并将待分类样本归类到与平均特征向量最邻近的类别中,即

$$y^* = \arg \min_{y=1, \dots, t} \|\varphi(x) - \mu_y\| \quad (7)$$

其中: x 为某待分类样本。

算法4:最邻近均值分类器

输入 x //健康状态样本

输入 $P = (P_1, \dots, P_t)$ //范例集合

输入 $\varphi: \mathcal{X} \rightarrow \mathbb{R}^d$ //特征向量

for $y=1, \dots, t$ do

$$\mu_y \leftarrow \frac{1}{|P_y|} \sum_{p \in P_y} \varphi(p) // 范例均值$$

end for

$$y^* \leftarrow \arg \min_{y=1, \dots, t} \|\varphi(x) - \mu_y\| // 最邻近分类$$

输出 健康状态类别标签 y^*

2.4 增量学习

图2为增量学习算法流程。①数据预处理:先对新健康状态采集的信号进行数据预处理,包括样本划分、样本归一化,其次合并旧范例及新样本为新训练集。②网络训练:使用梯度下降法,基于新训练集训练多源传感融合网络,具体见算法1。③分类:通过最邻近均值分类器对网络输出的特征进行健康状态分类,具体见算法4。④范例管理:因存储空间限制,在下次在线训练前,重新调整旧健康状态保留的范例数量,具体见算法2,3。

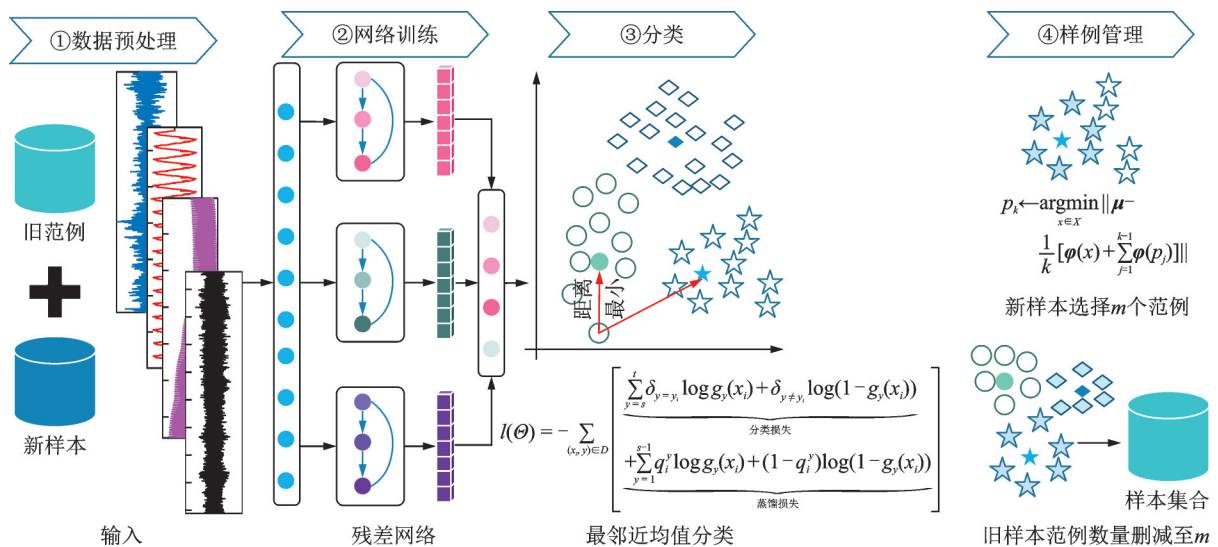


图2 增量学习算法流程

Fig.2 Flowchart of incremental health state assessment algorithm

算法5:增量学习

输入 X', \dots, X' // t 类健康状态训练样本

输入 K //可存储样本总量

输入 Θ //当前模型参数


```

Θ ← 多源信息融合网络训练(Xs, ..., Xt; P, Θ)
m ← round(K/t) // 每组范例数量
for y=1, ..., s-1 do
    Py ← 旧范例数量变更(Py, m)
end for
for y=s, ..., t do
    Py ← 新范例管理(Xy, m, Θ)
end for
P ← (P1, ..., Pt) // 新范例集合
    
```

3 实验

3.1 实验设计

采用核电循环水泵实验台获取泵导轴承劣化数据来验证所提方法的有效性。实验台由中国核电工程有限公司、上海阿波罗机械股份有限公司及西安交通大学联合搭建。循环水泵实验台如图3所示,主要包括电机、行星齿轮箱、导轴承和叶轮等部件。电机与齿轮箱的输入方式采用齿式联轴器;齿轮箱与循环水泵之间采用刚性直联方式;运动与动力由主电机传至齿式联轴器,然后经一级行星传动,将运动和动力传输至输出轴连接法兰,驱动循环水泵工作。泵导轴承为可倾瓦轴承,泵叶轮为离心式叶轮。实验台数据采集系统包括振动加速度传感器、声压传感器、轴位移传感器、温度传感器和数据采集仪等。采样频率为10 240 Hz,采样点数为32 768,采样间隔为60 s。数据采集过程如图4所示。

循环泵导轴承全寿期实验共耗时25.28 h,循环水泵实验台参数如表1所示。为加速导轴承劣化趋势,实验在无润滑油条件下进行。由于调整流量偏




图3 循环水泵实验台

Fig.3 Circulating water pump test bench




图4 数据采集过程

Fig.4 Data acquisition process

表1 循环水泵实验台参数

Tab.1 Parameter of circulating water pump bench

循环参数	数值	齿轮箱参数	数值
电机功率/kW	37	输入转速/(r·min ⁻¹)	1 448
叶轮外径/mm	578	输出转速/(r·min ⁻¹)	337
扬程/m	5.2	传动比	4.4
进水压力/MPa	0.020	行星轮个数	4
出水压力/MPa	0.065	太阳轮个数	1
导轴承瓦片数	6	行星轮齿数	23
额定流量/(m ³ ·h ⁻¹)	295	太阳轮齿数	20

离设计点可增加泵的径向力及轴向力^[14],因此实验拟将流量由额定流量295 m³/h减小至144 m³/h以加速导轴承劣化速度。本实验主要研究电机、齿轮箱和叶轮处于正常状态时,在乏油、流量突变条件下导轴承劣化程度与物理监测信号间的表征关系。

3.2 实验结果

图5为循环泵导轴承实验结果。在将流量由295 m³/h减小至144 m³/h时,轴系稳定性逐渐被破坏,表现为轴瓦温度逐渐上升,振动幅值偶有增大,轴位移及声压发生突变,且轴心轨迹呈8字形。

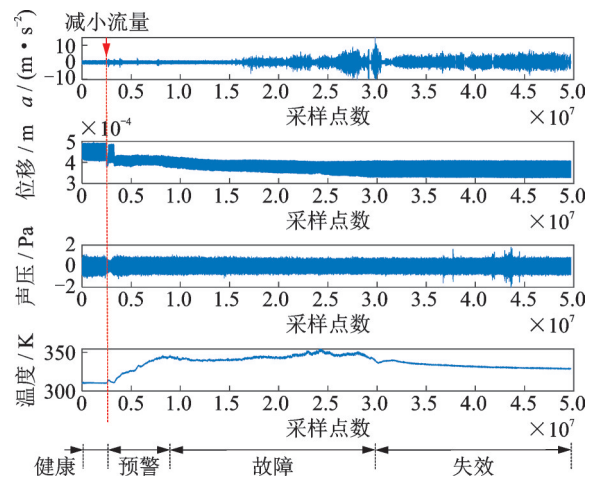


图5 循环泵导轴承实验结果

Fig.5 Test on circulating water pump bearing

图6为循环泵导轴承提纯轴心轨迹。综合上述现象,可判断故障为因轴系不对中引起碰磨^[15],因此将流量调整前所收集到的样本标记为健康。发生碰磨后,温度在一段时间内急速上升至344 K左右,期间振动加速度幅值偶有增大,推测为碰磨的发展期,标记该阶段收集的数据为预警,在此阶段轴位移及声压信号变化不明显。轴瓦温度急剧上升一段时间后逐渐趋于平稳,此时轴位移和振动加速度振幅逐渐增大,转子的稳定性进一步降低,标记该阶段为故




图6 循泵导轴承提纯轴心轨迹

Fig.6 Orbit of circulating water pump bearing

障,此时声压和温度变化较小。在振动加速度幅值增大至极限 10 m/s^2 后,观察到振幅、温度逐渐降低,轴位移保持不变,声压幅值增大,现场可听见异音,推测轴瓦经过一段时间“跑和”后趋于平稳,但此时振幅维持在 3 m/s^2 ,已超过正常阈值,标记该阶段为失效。

由实验过程可看出,在核电循泵导轴承故障发展的不同阶段,监测物理量对故障的敏感性差异较大。在碰磨故障初期,轴与轴瓦发生碰磨,温度在早期上升较快,而后逐渐稳定,此时若仅依据温度判断导轴承健康状态,无法反映其真实运行状态。

为克服单一物理监测信号导致的健康状态评估精度降低问题,笔者设计多源信息融合网络,通过提取振动加速度、声压、位移和温度信号的高维融合特征,提升评估模型准确率,实现循环水泵导轴承的可靠健康评估。实验中,齿轮箱与泵导轴承距离约为 940 mm ,转速和流量几乎处于稳态,齿轮箱振动和流体噪声影响较小。导轴承为可靠性高的动压滑动导轴承,核电企业会在故障前对其更换。上述因素导致难以收集足量的故障数据进行离线模型训练。笔者提出的增量评估方法可在设备运行时实时收集数据和在线训练模型,实现核电循泵导轴承的增量健康状态评估,具有良好的工程应用前景。

3.3 循泵健康状态增量评估

3.3.1 参数设置

设样本长度为 $4\ 096$,滑动窗偏移量为 $2\ 048$,并对样本进行归一化。当每种状态的最后一个样本数据点不足 $4\ 096$ 时,则丢弃该部分数据。设可存储样本总量为 $K=500$,每一次增量评估模型训练 30 次,网络训练采用随机梯度下降方法,设学习率为 0.002 。多源信息融合网络参数如表 2 所示。

表2 多源信息融合网络参数

Tab.2 Parameters of multi-signal fusion network

CNN (64, 1, 1)		
BN		
ReLU		
残差块 (64, 3, 1)	残差块 (64, 5, 1)	残差块 (64, 7, 1)
BN	BN	BN
ReLU	ReLU	ReLU
残差块 (128, 3, 1)	残差块 Conv (128, 5, 1)	残差块 (128, 7, 1)
BN	BN	BN
ReLU	ReLU	ReLU
残差块 (256, 3, 1)	残差块 (256, 5, 1)	残差块 (256, 7, 1)
BN	BN	BN
ReLU	ReLU	ReLU
残差块 (512, 3, 1)	残差块 (512, 5, 1)	残差块 (512, 7, 1)
BN	BN	BN
ReLU	ReLU	ReLU
全局最大池化	全局最大池化	全局最大池化
合并 (512×3)		
全连接层 (512×3, 256)		
ReLU		
线性层 (256, 64)		

3.3.2 实验结果

设导轴承初始数据集分为 3 类:①健康;②健康+预警;③健康+预警+故障。健康状态评估准确率如表 3 所示。

表3 健康状态评估准确率

Tab.3 Accuracy of bearing health state assessment

初始数据集	故障类别		
	预警	故障	失效
健康	94.58	96.96	94.44
健康+预警	—	98.04	94.90
健康+预警+故障	—	—	95.35

由表 3 可知,在新样本到来时,基于不同初始数据集训练的评估模型精度都可维持在 94% 以上,表明在不同初始数据条件下,所提方法具有较好的自适应性。随着新健康状态类别的增多,方法评估准确率下降约 $2\% \sim 4\%$,但仍保持在 90% 以上。

对健康状态评估结果绘制 3 种类型的混淆矩阵,如图 7~9 所示。其中:0 表示健康状态,1 表示预警状态,2 表示故障状态,3 表示失效状态。由图 7 可以看出,在增加新任务后,所提方法在任一健康状态评估中均能保持在 85% 以上的评估准确率。

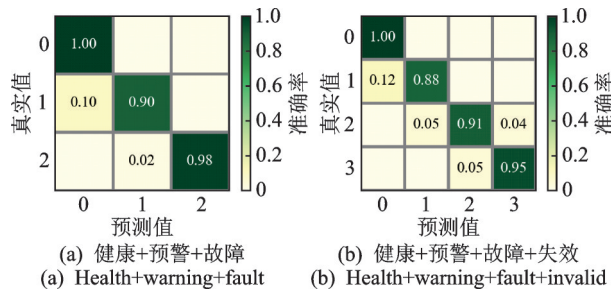


图7 仅有健康样本混淆矩阵

Fig.7 Confusion matrix with only health samples

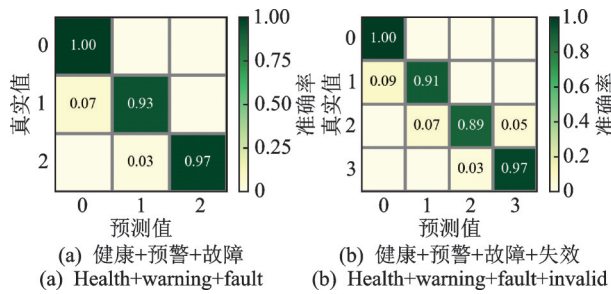


图8 健康和预警2种样本混淆矩阵

Fig.8 Confusion matrix with health and warning samples




图9 健康、预警和故障3种样本混淆矩阵

Fig.9 Confusion matrix with health, warning and fault samples

对比图7~9发现,随着在线新健康状态增多,健康状态增量评估的准确率略有降低。增多初始健康状态数量可提升算法的准确率,在本次实验中,增多一类初始健康状态类别,准确率增加约0.5%。

3.3.3 对比分析

为进一步验证所提方法的有效性,将所提方法与微调^[16]、无遗忘学习(learning without forgetting,简称LWF)^[17]方法进行对比。相较于所提方法,微调将损失函数修改为交叉熵函数,将分类器由最邻近均值分类器改为神经网络线性层,设置参数为(64,4),并停用范例管理策略。LWF将分类器由均值最邻近分类器改为神经网络,并停用范例管理策略,其他超参数与所提方法一致。表4为导轴承健康状态评估准确率。可以看出,所提方法相较微调和LWF,在3种情况下的评估准确率均有一定提升,表明所提方法的优越性。

表4 导轴承健康状态评估准确率
Tab.4 Accuracy of bearing health state assessment %

方法	初始数据集		
	健康	健康+预警	健康+预警+故障
微调	38.43	38.43	37.55
LWF	37.22	43.95	26.68
所提方法	94.58	96.96	94.44

2种对比方法混淆矩阵如图10所示。图10显示,微调方法将健康、预警和故障样本均评估为失效状态,说明基于深度神经网络的健康状态评估模型在学习新知识后,几乎完全遗忘之前的内容。这是因为神经网络模型主要由网络结构和参数构成,网络结构决定了模型的存储容量。当参数容量一定时,网络模型会因为学习新任务而遗忘旧任务知识。此外,神经网络中的神经元是全局的,当网络结构固定时,新数据会影响与历史知识相关的参数,导致新任务知识覆盖旧任务知识^[18-19]。

相较于微调,LWF虽然准确率较低(如图10(b)所示),但可保留部分对旧健康状态的评估能力,表明蒸馏损失在保存旧模型知识上仍有一定作用。由于泵导轴承健康状态评估为单类别增量任务,数据分布差异大,导致旧模型知识难以通过蒸馏损失提取,评估精度较低。总体来看,所提方法具有较高的评估准确率。




图10 2种对比方法混淆矩阵

Fig.10 Confusion matrix of two comparison method

4 结束语

所提方法可有效提取高维融合特征,保证在固定存储空间下评估模型的在线更新能力,实现导轴承健康状态增量评估。通过搭建核电循环水泵实验台架,采集导轴承劣化数据来验证所提方法的准确率和有效性。实验结果表明,在相同条件下所提方法的准确率在94%以上,高于微调及LWF方法。

参 考 文 献

- [1] 张永, 龚众望, 郑英, 等. 工业设备的健康状态评估和退化趋势预测联合研究[J]. 中国科学(技术科学), 2022, 52(1): 180-197.
ZHANG Yong, GONG Zhongwang, ZHENG Ying, et al. Joint study on health state assessment and degradation trend prediction of industrial equipment[J]. Scientia Sinica (Technologica), 2022, 52(1): 180-197. (in Chinese)
- [2] CHEN S X, ZHOU L, NI Y Q. Wheel condition assessment of high-speed trains under various operational conditions using semi-supervised adversarial domain adaptation[J]. Mechanical Systems and Signal Processing, 2022, 170: 108853.
- [3] 尹爱军, 王昱, 戴宗贤, 等. 基于变分自编码器的轴承健康状态评估[J]. 振动、测试与诊断, 2020, 40(5): 1011-1016.
YIN Aijun, WANG Yu, DAI Zongxian, et al. Bearing health assessment with variational autoencoder[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(5): 1011-1016. (in Chinese)
- [4] ZHANG Y, XIN Y Q, LIU Z W, et al. Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE [J]. Reliability Engineering & System Safety, 2022, 220: 108263.
- [5] SHAO H D, LI W, XIA M, et al. Fault diagnosis of a rotor-bearing system under variable rotating speeds using two-stage parameter transfer and infrared thermal images[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [6] KIRKPATRICK J, PASCANU R, RABINOWITZ N, et al. Overcoming catastrophic forgetting in neural networks[J]. Proceedings of the National Academy of Sciences of the United States of America, 2017, 114(13): 3521-3526.
- [7] BELOUADAH E, POPESCU A, KANELLOS I. A comprehensive study of class incremental learning algorithms for visual tasks[J]. Neural Networks, 2021, 135: 38-54.
- [8] REBUFFI S A, KOLESNIKOV A, SPERL G, et al. ICaRL: incremental classifier and representation learning [C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 5533-5542.
- [9] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [10] LIU R N, WANG F, YANG B Y, et al. Multiscale kernel based residual convolutional neural network for motor fault diagnosis under nonstationary conditions[J]. IEEE Transactions on Industrial Informatics, 2020, 16(6): 3797-3806.
- [11] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[DB/OL]. (2015-03-09) [2022-06-24]. <https://arxiv.org/abs/1503.02531>.
- [12] DE BOER P T, KROESE D P, MANNOR S, et al. A tutorial on the cross-entropy method[J]. Annals of Operations Research, 2005, 134(1): 19-67.
- [13] MENSINK T, VERBEEK J, PERRONNIN F, et al. Distance-based image classification: generalizing to new classes at near-zero cost [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2624-2637.
- [14] 关醒凡. 现代泵理论与设计[M]. 北京: 中国宇航出版社, 2011: 564-596.
- [15] 屈梁生. 机械故障的全息诊断原理[M]. 北京: 科学出版社, 2007: 61-77.
- [16] KÄDING C, RODNER E, FREYTAG A, et al. Fine-tuning deep neural networks in continuous learning scenarios[C]//Computer Vision-ACCV 2016 Workshops. Cham: Springer International Publishing, 2017: 588-605.
- [17] LI Z Z, HOIEM D. Learning without forgetting [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(12): 2935-2947.
- [18] MCCLOSKEY M, COHEN N J. Catastrophic interference in connectionist networks: the sequential learning problem [J]. Psychology of Learning and Motivation, 1989, 24: 109-165.
- [19] FRENCH R M. Catastrophic forgetting in connectionist networks [J]. Trends in Cognitive Sciences, 1999, 3(4): 128-135.



第一作者简介:刘雪,女,1994年9月生,博士生。主要研究方向为机械设备故障诊断与预测。曾发表《AFARN: Domain adaptation for intelligent cross-domain bearing fault diagnosis in nuclear circulating water pump》(《IEEE Transactions on Industrial Informatics》2023, Vol.19, No.3)等论文。

E-mail: xueliu@stu.xjtu.edu.cn

通信作者简介:成玮,男,1983年6月生,博士、教授、博士生导师。主要研究方向为高端装备智能运维与健康管理。

E-mail: chengw@mail.xjtu.edu.cn