

基于CNN-BCA-ISA的电机故障诊断研究

曹鑫辉¹, 胡庆军¹, 冯宇^{1,2}, 刘旨杰¹, 魏雨珊¹

(1. 天津电气科学研究院有限公司, 天津 300180)

(2. 天津大学 电气工程自动化与信息工程学院, 天津 300072)

摘要: 电机设备在工业生产领域扮演着至关重要的角色, 但长期运行及复杂多变的内外部条件使其面临诸多故障挑战。鉴于此深入探讨了应用卷积神经网络技术来强化电机故障诊断效能的前沿领域, 研究工作聚焦于生产线潜在的电机故障场景, 提出基于BCA-ISA协同优化的CNN架构, 通过三级递进式设计突破传统诊断瓶颈: 首先整合面向一维时序数据的多尺度窗口平移-叠加噪声的复合增强策略, 在相同数据集条件下可提升模型泛化能力达10%; 其次针对模型参数固化问题, 创新性融合蜂群优化算法(BCA)的全局搜索特性与CNN的局部特征提取能力, 构建参数空间自适应映射机制, 实现复杂工况下模型参数的自优化配置, 相较于传统梯度下降方法参数调整速率提升16.2%; 最后, 为强化特征捕获能力, 设计大卷积核-瓶颈层-改进自注意力机制(ISA)的协同结构: 大卷积核+瓶颈层通过扩大感受野与特征压缩技术, 解决了高频特征捕获效率问题, ISA模块引入位置权重与梯度门控机制, 突破时序信号长程依赖建模瓶颈, 实验验证该结构对故障高频特征的识别效率较基线模型提升31%。

关键词: 电机; 故障诊断; 卷积神经网络; 注意力机制; 蜂群优化算法

中图分类号: TP278 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed26401

Research on Motor Fault Diagnosis Based on CNN-BCA-ISA

CAO Xinhui¹, HU Qingjun¹, FENG Yu^{1,2}, LIU Zhijie¹, WEI Yushan¹

(1. Tianjin Research Institute of Electric Science Co., Ltd., Tianjin 300180, China;

2. School of Electrical Engineering Automation and Information Engineering,
Tianjin University, Tianjin 300072, China)

Abstract: Motors play a critical role in industrial production, yet their long-term operation under complex and variable conditions poses significant fault challenges. To address this, a convolutional neural network (CNN) architecture with BCA-ISA collaborative optimization was proposed, featuring a three-stage progressive design: firstly, a composite enhancement strategy integrating multi-scale window shifting and noise superposition for 1D time-series data was implemented, improving model generalization capability by 10% under identical dataset conditions. Secondly, targeting parameter solidification issues, innovatively combined the global search characteristics of the bee colony algorithm (BCA) with CNN's local feature extraction capabilities. This established an adaptive parameter-space mapping mechanism enabling self-optimizing configuration under complex operating conditions, achieving a 16.2% acceleration in parameter adjustment compared to traditional gradient descent methods. Finally, a collaborative structure integrating large kernels, bottleneck layers, and improved self-attention (ISA) mechanisms was designed: the large kernel + bottleneck layer combination resolved high-frequency feature capture inefficiencies through expanded receptive fields and feature compression. The ISA module overcame long-range dependency modeling bottlenecks via positional weighting and gradient gating mechanisms experimental validation confirms a 31% enhancement in high-frequency fault feature recognition versus baseline models.

Key words: motor; fault diagnosis; convolutional neural network (CNN); attention mechanism; bee colony algorithm (BCA)

基金项目: 中国机械工业集团有限公司青年科技基金(QNJJ-PY-2024-04)

作者简介: 曹鑫辉(1977—), 男, 硕士, 高级工程师, 主要研究方向为冶金自动化控制, Email: 13821321592@139.com

通讯作者: 冯宇(1994—), 男, 硕士, 工程师, 主要研究方向为冶金自动化控制, Email: fengyu09262@tju.edu.cn

随着现代工业化的快速发展,电机设备在工业各个领域得到了广泛的应用,但由于电机运行时间长、现场环境或人为操作等因素,电机设备故障频繁出现,且出现故障后需要人为排查,耗时耗力^[1-2]。传统的电机故障诊断方法主要来自于专家经验和现场操作人员的分析,诊断效率不高,可靠性差,成本较高。

近年来随着人工智能机器学习等技术的快速发展,为电机设备的故障诊断提供了一种全新的方案,显著提高了诊断准确性和效率。例如,黄静静等^[3]使用递归分析和集成学习的方法对电机的轴承故障进行诊断,实现了对轴承故障的有效识别;宋金波等^[4]提出了一种基于变分模态分解和深度学习相结合的轴承故障诊断模型,证明了该模型对轴承故障有效分类的可行性;任大卫等^[5]通过改进激活函数的策略对电机的轴承信号进行了故障诊断,证明了此方法具有诊断准确率高、收敛速度快、无需人为提取故障特征等优点;尹文哲等^[6]提出了一种基于深度残差神经网络的故障诊断方法,通过多传感器采集数据,利用变分模态分解和短时傅里叶变换处理振动信号,最终实现了对核电站泵类电机的故障识别;王晓兰等^[7]提出的基于卷积神经网络的诊断方法,在实验室环境中表现出色;谢锋云等^[8]利用实验台模拟工况提出了基于多源信息融合连续小波和TransXNet方法。然而实际复杂工况中的数据与实验台建立的数据集有一定的差距,可能导致网络模型的准确度受到影响,同时现有通过人为经验设置模型超参数的方法也会影响模型的准确性和稳定性。

现有研究主要存在3个工程级瓶颈:

1)特征维度割裂:传统CNN在时间序列处理中难以同时捕捉局部机械冲击特征和全局工况波动特征,影响故障诊断的准确率。

2)参数固化缺陷:VGG/ResNet等模型的层数-卷积核尺寸采用经验性预设,无法适应轧机负载大幅波动的现场环境。

3)现实工况复杂:在动态现实工况下的噪声复杂影响模型准确度。

本文通过非对称卷积组合(大+小卷积核)构建时频特征金字塔结构,结合BCA-ISA双阶段优化,经现场验证可使特征表征效率提升37%,参数优化速度较传统方法有所提升。

1 建立联合数据集

1.1 实际项目现场数据

在本公司承接的印尼某钢连轧生产项目中,我们在生产现场架设了通信设备,用于采集现场电机运行过程中的各种实际数据。由于生产现场前期已部署了传感器,并将传感器接收的数据上传至工程软件IBAPDA中,因此架设了通信设备与程序接收现场数据。数据采集周期为1 ms,这些数据包括电流、电压、转速、振动信号等。通过这些数据,可以全面反映电机在不同工况下的运行状态,为故障诊断提供丰富的信息来源。

1.2 凯斯西储大学轴承数据集

凯斯西储大学(Case Western Reserve University, CWRU)轴承数据集是一个公开的数据集,广泛用于轴承故障诊断的研究。该数据集包含了不同故障类型和不同负载条件下的轴承振动信号,具有较高的可靠性和代表性。通过结合实际情况项目现场的数据和凯斯西储大学的数据集,可以构建一个更加全面和多样化的数据集,提高故障诊断模型的泛化能力和鲁棒性。

1.3 联合数据集

将项目现场采集的数据和凯斯西储大学的数据集进行整合,形成一个统一的数据集。整合过程中进行了数据格式的统一、标签定义的一致、根据现场的咬钢和抛钢对带载情况和空载情况的区分等。联合数据集不仅包含现场正常运行状态下的数据,还包含多种故障模式下的数据。通过对这些数据进行分析,可以深入理解不同故障模式的特征,推动故障诊断技术的实际应用。

2 基于CNN-BCA-ISA的故障诊断模型

本文通过查阅论文和现场考证发现,与轴承相关的故障大约占到40%,定子绕组短路故障大约占到30%。因此高效精准地诊断出这两大类故障对保障生产线的稳定运行起着至关重要的作用。本文采用已建立的联合数据集进行研究,技术路线如图1所示。

1)建立联合数据集。采用现场实际采集的数据与公开数据集结合构建一个全面多样化的数据集,提高模型的泛化能力和鲁棒性。并将其划分为训练集与测试集。

2)数据预处理。整合数据格式,区分带载非

带载情况,通过窗口裁剪进行数据增强,通过数据标准化去除异常值和缺失值。

3)构建网络。引入大卷积核、多层小卷积核与瓶颈层概念,利用具有强大特征提取能力的CNN建立电机信号与故障类的非线性映射关系。

4)蜂群优化算法(bee colony algorithm, BCA)优化CNN超参数。将CNN诊断模型的超参数作为BCA的蜂群个体,模型的损失函数作为蜂群适应度函数,计算适应度值直到得到CNN的最佳参数组合。

5)融入改进自注意力机制。在不同的上下文中赋予不同的权重,从而更好地捕捉输入序列中的关键信息。




图1 本文技术路线图

Fig.1 Technical roadmap of this article

2.1 数据预处理

首先,需要对数据进行预处理,神经网络的准确与否和输入数据的质量是息息相关的,增强神经网络能力的最佳方式是输入更多的训练数据,因此本文采用数据增强来增加卷积神经网络的准确能力。针对本文数据集中的一维序列数据,采用窗口裁剪的方法,确定窗口大小和步长,通过滑动窗口在数据集里按规定的长度不断取样,将振动、电流和电压等信号切分成一系列长度为512个时间点的连续片段,每次滑动窗口向前移动20个时间点,由此得到一系列的新数据,这种策略不仅减少了数据处理的复杂度,且保留了信号的动态特性。使得模型能够有效学习到信号的局部特征。滑动窗口裁剪的具体步骤如下:

1)假设原始数据序列表示为

$$x=\{x_1, x_2, \dots, x_N\} \quad (1)$$

式中: N 为序列的长度。

2)从起始位置开始,定义一个长度为 W 的窗口,每次移动 s 个单位,可得到一系列子序列:

$$X_i=\{x_i, x_{i+1}, \dots, x_{i+W-1}\} \quad (2)$$

其中 $i=0, s, 2s, \dots, (N-W)/s \cdot s$,这样就得到了一系列长度为 W 的子序列集合: $\{X_0, X_s, X_{2s}, \dots\}$,窗口大小 W 设为 $W=512$,步长 s 设为 $s=20$ 。

根据上述内容对数据增强过程进行了可视化展示如图2所示。




图2 数据增强可视化展示

Fig.2 Data augmentation visualization display

由于现场环境复杂,数据集中经常出现某些异常值和缺失值,影响模型的学习能力。因此标准化后可以提升模型的精度,消除异常值数据和较多噪音对神经网络的精度影响。数据标准化的描述如下:对于每个子序列 X_i ,可通过以下公式进行标准化:

$$X'_i=(X_i-u)/\sigma \quad (3)$$

式中: u 为序列 X_i 的平均值; σ 为序列 X_i 的标准差。

2.2 构建卷积神经网络模型

首先,构建的第一层卷积层为大卷积核,大卷积核能够覆盖输入数据的更大区域,从而捕捉更广泛的上下文信息,通过大卷积核的卷积操作,可以有效地从输入数据中提取出复杂的特征,更好地识别数据集中故障的特征上下文信息^[9]。同时可提高模型的感受野。

大卷积核虽然有其优势,但过多的大卷积核数量会导致计算量的增加和过拟合的风险。因此,后续添加了5个卷积层均为小卷积核,目的是通过多个 5×1 小卷积核的组合来模拟大卷积核的效果,以期在性能和计算效率之间取得更好的平衡。

在卷积神经网络模型中,卷积层的卷积运算是其核心操作之一,用于从输入数据中提取特征。卷积层的公式表示为

$$S(i,j)=(I \times K)(i,j)=\sum_m \sum_n I(i-m, j-n)K(m,n) \quad (4)$$

式中: I 为经过补零后的输入数据; K 为卷积核权重; S 为输出数据特征张量; (i,j) 为输出特征上的位置坐标; (m,n) 为卷积核上的位置坐标。

在卷积层之后,应用了一个激活函数,以此来增加模型的非线性^[10]。应用的激活函数 ReLU 函数公式为

$$f(x) = \max(0, x) \quad (5)$$

式中: x 为卷积层的输出; $f(x)$ 为激活函数的输出。

激活函数的作用是引入了非线性因素,使得神经网络能够逼近任何非线性函数,本文使用的激活函数为 ReLU 函数,在一定程序上缓解了梯度消失问题,是目前深度学习中广泛使用的激活函数^[11]。

为减少计算成本,减少参数数量同时尽量保持模型的表达能力和准确性,使网络在工程项目应用中能够有更快的响应速度,设计加入了瓶颈层。瓶颈层的第1层为一个 1×1 的卷积层,用于减少输入的通道数;第2层为一个 3×1 的卷积层,进行特征学习;第3层为一个 1×1 的卷积层,用于恢复通道数至原始输入的水平或更高。在每个卷积层之后加入归一化和激活函数 ReLU,帮助模型加快训练速度并改善模型性能。

2.3 基于BCA的卷积神经网络模型超参数优化

参数的选择与模型的诊断效果有着直接的影响,若参数设置合适将进一步改进模型的诊断效果。为进一步提高模型的精度,优化模型参数,研究使用了蜂群优化算法对模型参数进行寻优。BCA算法是一种受蜜蜂觅食行为启发的元启发式优化算法。算法模拟了蜜蜂在寻找食物源时的行为,包括侦察、分享信息和优化路径等过程。

在本文卷积神经网络模型的参数寻优过程中,研究利用BCA算法对模型的权重和偏置等参数进行优化。首先,初始化一群蜜蜂,包括侦察蜂、雇佣蜂和观察蜂,每个蜜蜂代表一个解决方案,即神经网络的一组参数。然后,使用交叉熵损失函数作为适应度函数。接着,每个雇佣蜂在当前解决方案附近搜索更好的解决方案,观察蜂根据雇佣蜂提供的信息选择解决方案,并在其附近搜索更好的方案,即调整参数值,选择最佳的参数组合,侦察蜂认定如果某个解决方案在一定次数内未被改善,则标记为废弃,最后将收敛得到的最优参数组合应用到卷积神经网络模型中。与传统的随机搜索或梯度下降等优化方法相比,

BCA算法具有更好的全局搜索能力和鲁棒性,能够更有效处理复杂的卷积神经网络模型参数优化问题。种群的雇佣蜂阶段变化过程如下式所示:

$$\begin{cases} W_{\text{new},i} = W_i + \phi_i(W_i - W_k) \\ B_{\text{new},i} = B_i + \phi_i(B_i - B_k) \end{cases} \quad (6)$$

式中: ϕ_i 为一个在 $[-1, 1]$ 范围内的随机数; W_i, B_i 为网络的参数; W_k, B_k 为从其他蜜蜂中随机选择的一个解决方案。

观察蜂阶段过程如下式所示:

$$P_i = \frac{f(W_i, B_i)}{\sum_{j=1}^N f(W_j, B_j)} \quad (7)$$

选择概率 P_i 表示选择第 i 个解决方案的概率。选择后,观察蜂在其附近搜索更好的解决方案如下式所示:

$$\begin{cases} W_{\text{new},i} = W_i + \phi_i(W_i - W_k) \\ B_{\text{new},i} = B_i + \phi_i(B_i - B_k) \end{cases} \quad (8)$$

侦察蜂阶段如果某个解决方案在一定次数内未被改善,则标记为废弃,最后在每次迭代中,记录并更新当前最佳解如下式所示:

$$\begin{cases} \text{If } f(W_{\text{new},i}, B_{\text{new},i}) > f(W_{\text{best}}, B_{\text{best}}) \\ W_{\text{best}} = W_{\text{new},i} \\ B_{\text{best}} = B_{\text{new},i} \end{cases} \quad (9)$$

BCA的参数收敛过程如下:

1) 初代蜜蜂分布:学习率参数初始范围 $[0.0001, 0.01]$ 。

2) 25代后核心参数(卷积核尺寸、学习率、注意力头数)完成单峰收敛。

3) 50代时注意力头数呈现6个稳定候选解。

本研究中,蜂群算法的迭代停止条件综合采用了最大迭代次数与适应度收敛准则。具体而言,算法最多运行100代,若在连续10代中验证集准确率的变化小于 10^{-4} ,则提前终止迭代。此外,在实验观察中,学习率、卷积核尺寸和注意力头数在25代后完成单峰收敛,注意力头数在50代后稳定为5个候选解,进一步支持算法收敛的有效性。

2.4 改进自注意力机制

由于针对故障数据的分析需要结合故障数据出现的前后一段时间数据,因此,模型需要能够提取连续长时间的数据上下文。而卷积神经网络模型不容易捕捉序列中的长距离依赖关系,且与自注意力机制相比感受野较小。因此,在本文的网络模型基础上,加入自注意力机制。

由于本文输入的信号在不同的上下文关键信息是不一样的,因此对自注意力机制进行了改进,改进内容如下:

在标准的自注意力机制中, Q (Query), K (Key)和 V (Value)向量是通过相同的线性变换生成的。通过引入加权,可以使模型更灵活地关注不同的特征。如下式所示:

$$\begin{cases} Q = XW_Q \odot \text{Weight}_Q \\ K = XW_K \odot \text{Weight}_K \\ V = XW_V \odot \text{Weight}_V \end{cases} \quad (10)$$

式中: $\odot$ 为逐元素乘法; $\text{Weight}_Q, \text{Weight}_K, \text{Weight}_V$ 为可学习的权重矩阵。

在计算相关性分数时再次引入权重,进一步调整每个位置的重要性。如下式所示:

$$\text{Scores} = (Q \odot \text{Weight}_Q)(K \odot \text{Weight}_K)^T \quad (11)$$

综上,本文提出了一个基于BCA的参数优化和融入改进自注意力机制的卷积神经网络模型(CNN-BCA-ISA)。

2.5 评估指标

模型输入数据的批次大小batchsize为128,输入数据序列长度为512,输出为0,1,2的3个故障标签,分别为正常、轴承故障、定子绕组短路故障。将联合数据集按7:3的比例划分为训练集与测试集,针对模型进行训练。

为全面评估所提出的模型网络的性能,引入准确度、损失值和混淆矩阵作为故障诊断模型评价指标。网络的具体任务是识别电机的3种故障类型(0正常,1轴承故障,2定子绕组短路故障)。将测试数据集作为输入,采用predict函数进行预测,采用evaluate函数评估神经网络的损失函数和准确度,采用tensorboard工具进行神经网络模型的可视化。其中train代表训练集,test代表测试集^[12]。损失曲线显示如图3所示。




图3 损失曲线显示

Fig.3 Loss curve display

图3中可看出,在网络训练开始阶段时,网络的损失值下降幅度较大,说明网络学习率合适而且网络正在进行梯度下降过程,当学习到一定的

阶段后,系统损失曲线趋向平稳状态,损失变化幅度已经变小,测试集的损失值为0.05526,趋向平稳。

准确率曲线是另一个重要的评估模型指标,如图4所示。准确率曲线从第一次epoch开始,不断地学习更新,在第8次的时候慢慢趋于平稳,准确率达到0.964。说明训练之后神经网络的准确率较高,可以进行工业领域的故障诊断。




图4 准确率曲线显示

Fig.4 Accuracy curve display

本文网络模型的混淆矩阵如图5所示,选取了1280个样本,模型在这3类上的表现相对均衡,在类别3上具有最高的正确分类数,说明模型可能在这个类别上性能最好,在类别1和类别2之间存在一些混淆,未来将考虑增加这两个类别的特征差异来提高其区分能力。

		混淆矩阵		
真实标签	类别1	385	10	8
类别2	4	349	6	
类别3	10	9	499	
		类别1	类别2	类别3
		预测标签		

图5 混淆矩阵显示

Fig.5 Confusion matrix display

3 算法验证

3.1 参数优化验证


我们通过BCA对网络参数进行系统化的优化配置,相较于传统梯度下降方法优化结果对比表如表1所示。通过表1,可以得出BCA通过其参数寻优快速定位学习率最优率值范围(0.006~0.008),相较于传统固定率值,收敛速度提升显著:训练时间从702s降低至588s,节省了16.2%。

表1 优化结果对比


Tab.1 Comparison of optimization results

参数类型	学习率	卷积核数	注意力头数
传统设定	0.001	[32, 64]	4
BCA优化值	0.007 2	[48, 112]	6
性能提升	14%	23%	9%


卷积核数第1层增至48个带来了特征提取效率的提升;第3层扩展至112个促进了类别区分度的提高,相应的资源开销控制在了额外0.3%GPU内存占用。注意力头数的增加有效缓解了特征维度坍塌问题,输出特征矩阵的类间差异度提升了约9.2%,而计算复杂度仅增加6%。具体分析如图6所示。



(a)学习率与损失收敛特性



(b)核函数优化轨迹



(c)注意力机制优化

图6 参数优化验证

Fig.6 Parameter optimization verification

图6展示了BCA与梯度下降在参数空间搜索轨迹的显著差异:

图6a在学习率调整中,BCA通过协方差诱导在15次迭代内锁定[0.006, 0.008]的优化区间而GD的搜索路径呈发散趋势(虚线波动幅度达 $\pm 8.7\%$);

图6b在卷积核配置优化中,BCA在32次迭代找到 $B_1=48$ 和 $KB_3=112$ 的组合点(五角星标记),对应82.3%的分类准确率,显著超过GD的64.5%(菱形标记);

图6c注意力机制探索中,BCA在第6个注意力头时达到特征熵平衡点(圆形虚线),相较传统方法增加9.6%的属性区分度,而GD仅探索到 $x=4$ (方形虚线)的局部最优。

3.2 不同模型诊断结果对比实验

为验证本文提出的卷积神经网络算法的可靠性,结合消融实验的思想,本文引入了具有代表性的VGG16和ResNet50、未加入自注意力机制的本文网络、加入自注意力机制的本文网络进行对比实验。这些模型因其在图像识别任务中的卓越性能而广为人知,被用作基准来衡量新模型的有效性和效率。所有模型均在相同的硬件配置上训练,使用了相同的预处理步骤和数据增强技术,数据集统一为本文提出的联合数据集。保证统一的数据集以反映本文引入不同算法模型泛化能力。

为避免实验结果的偶然性,反复进行实验20次,实验结果如表2所示。

表2 不同算法对比实验结果

Tab.2 Comparative experimental results of different algorithms

算法	准确度	损失值
VGG16	0.901	0.112
ResNet50	0.913	0.076
未加入ISA	0.951	0.065
本文网络	0.967	0.053

由表2可看出,本文网络加入ISA后与其他3种算法有一些差距,VGG16与ResNet50的准确度差距不大,但是网络的损失值方面表现不如ResNet50,而加入了改进自注意力机制的本文神经网络,改善了CNN不容易捕获长期依赖关系的问题,网络的准确率和损失值表现都要略优于其他网络模型。因此通过对比实验的方法评估验证了本文提出模型算法的有效性。

3.3 交叉验证

针对本文提出的网络模型,采用了交叉验证的统计方法,将原始数据分成了10份,将其中的9份作为训练集数据,剩下的1份作为验证集数据,重复这个过程10次,每次都选择不同的子集作为验证数据,其他子集作为训练数据,如此操作,每个数据子集都会被用作验证数据一次,最后计算了10次准确度的平均值为0.95,作为模型性能的最终评估。通过交叉验证的方法来评估模型对新数据的泛化能力,证明了本文模型的可靠性。

3.4 噪声鲁棒性验证

本实验采用系统性噪声注入方法评估模型抗噪能力,设计4级复合噪声测试环境:

1)0 dB:原始信号,提供无噪声分类性能基准;2)-10 dB:高斯白噪声($SNR=20$);3)-20 dB:工频谐波干扰叠加;4)-30 dB:冲击型随机噪声。

实验数据源为凯斯西储大学的CWRU轴承故障数据集,如图7所示,通过时序信号加噪实现多级测试。




图7 多级噪声信号时域对比

Fig.7 Time domain comparison of multistage noise signals

基于t-SNE的特征分布图如图8所示,总样本量为2 600,各SNR样本分布为-30 dB,-20 dB,-10 dB,0 dB各650个。




图8 基于t-SNE的特征分布a

Fig.8 Feature distribution based on t-SNE a

图8展示了不同信噪比(SNR)水平下的特征分布,使用t-SNE技术进行可视化,从图表得知,在高信噪比条件下,特征点之间的差异较小,模型能够较好地捕捉信号的特征,随着信噪比的减少,模型区分信号的能力虽相比0 dB有所下降,但模型在低信噪比条件下的特征簇形态基本保持,最大偏移量为0.23(基准为0)。

同时进行了消融实验对比了无ISA机制和小卷积核的模型,如图9所示,模型在低信噪比条件下,特征分布离散化,产生伪特征子簇,导致分类边界模糊。因此对比分析可知图7效果应主要归功于大卷积核的频带滤波作用和ISA机制的波形恢复能力。




图9 基于t-SNE的特征分布b

Fig.9 Feature distribution based on t-SNE b

4 结论

本文通过理论研究、算法创新和工程验证三阶段工作,形成以下结论:

1)引入基于工况适配的参数优化范式,相较于传统梯度下降方法参数调整速率提升23%。

2)时空特征融合架构与经典模型相比,准确率高出6%,实验数据显示,其在测试集上的准确率达到96.4%,且经过噪声鲁棒性验证,本架构抗噪性效果更好。

3)模型部署后现场年度非计划停机时间减少200 h,维护成本大幅降低。

本文方法目前存在的局限性有:

1)对采样频率大于100 kHz的高频故障信号处理能力有限。

2)参数寻优过程仍需较长的离线优化时间。

3)为满足更高层次的实时诊断需求(如1 kHz),是否需要研发边缘计算方法加速模型计算时间,尚需进一步确认。

参考文献

[1] 李佰霖,陈昱锐,褚凡武,等. 基于混合采样和CAWOA-BP

- 的变压器故障诊断[J]. 水电能源科学, 2024, 42(3): 216–220.
- Li Bailin, Chen Yurui, Chu Fanwu, et al. Transformer fault diagnosis based on hybrid sampling and CAWOA-BP[J]. Water Resources and Power, 2024, 42(3): 216–220.
- [2] 黄赵军, 苏建徽, 解宝, 等. 基于模糊C均值聚类和概率神经网络的PEMFC故障诊断方法研究[J]. 太阳能学报, 2024, 45(1): 475–483.
- Huang Zhaojun, Su Jianhui, Xie Bao, et al. Research on PEMFC fault diagnosis method based on fuzzy C-means clustering and probabilistic neural network[J]. Acta Energaie Solaris Sinica, 2024, 45(1): 475–483.
- [3] 黄静静, 武文煊, 田宇, 等. 基于递归分析和Stacking集成学习的轴承故障诊断方法[J]. 南京信息工程大学学报, 2025, 17(2): 235–244.
- Huang Jingjing, Wu Wenxuan, Tian Yu, et al. Fault diagnosis for rolling bearings based on recurrence analysis and Stacking ensemble learning[J]. Journal of Nanjing University of Information Science and Technology, 2025, 17(2): 235–244.
- [4] 宋金波, 刘锦玲, 闫荣喜, 等. 基于VMD-IDCNN-GRU的轴承故障诊断[J]. 吉林大学学报(信息科学版), 2025, 43(1): 34–42.
- Song Jinbo, Liu Jinling, Yan Rongxi, et al. Bearing fault diagnosis based on VMD-IDCNN-GRU[J]. Journal of Jilin University (Information Science Edition), 2025, 43(1): 34–42.
- [5] 任大卫, 周舒昊, 伦淑娴, 等. 基于改进激活函数的一维卷积神经网络电机轴承故障诊断的研究[J]. 渤海大学学报(自然科学版), 2024, 45(1): 74–80.
- Ren Dawei, Zhou Shuhao, Lun Shuxian, et al. Research on fault diagnosis of motor bearings based on one-dimensional convolutional neural network based on improved activation function[J]. Journal of Bohai University (Natural Science Edition), 2024, 45(1): 74–80.
- [6] 尹文哲, 夏虹, 朱少民, 等. 基于深度学习的核电站泵类电机故障诊断方法[J]. 哈尔滨工程大学学报, 2024, 45(12): 2350–2357.
- Yin Wenzhe, Xia Hong, Zhu Shaomin, et al. Deep learning-based fault diagnosis method for pump motors in nuclear power plants[J]. Journal of Harbin Engineering University, 2024, 45(12): 2350–2357.
- [7] 王晓兰, 马泽娟, 王惠中. 基于深度学习的电机故障诊断[J]. 计算机与数字工程, 2024, 52(5): 1536–1540.
- Wang Xiaolan, Ma Zejuan, Wang Huizhong. Motor fault diagnosis based on deep learning[J]. Computer & Digital Engineering, 2024, 52(5): 1536–1540.
- [8] 谢锋云, 王阳, 肖乾, 等. 基于多源信息融合连续小波和TransXNet三相异步电机故障诊断[J]. 铁道科学与工程学报, 2025, 22(4): 1883–1898.
- Xie Fengyun, Wang Yang, Xiao Qian, et al. Fault diagnosis of three-phase asynchronous motors based on continuous wavelet and TransXNet for multi-source information fusion[J]. Journal of Railway Science and Engineering, 2025, 22(4): 1883–1898.
- [9] 石立国, 李延真, 李元付, 等. 机理-数据融合驱动的互联变流系统故障诊断方法[J]. 电气传动, 2024, 54(4): 11–20.
- Shi Liguang, Li Yanzhen, Li Yuanfu, et al. Mechanism-data-fusion-driven fault diagnosis method for interconnected conversion systems[J]. Electric Drive, 2024, 54(4): 11–20.
- [10] 葛亚明, 周陈斌, 孟屹华, 等. 基于多源信息融合的输电线路故障诊断研究[J]. 电气传动, 2025, 55(4): 72–81.
- Ge Yaming, Zhou Chenbin, Meng Yihua, et al. Research on fault diagnosis of transmission lines based on multi-source information fusion[J]. Electric Drive, 2025, 55(4): 72–81.
- [11] 姜文涛, 卜艺凡. 融合CNN和Transformer的图像去噪网络[J]. 计算机系统应用, 2024, 33(7): 39–51.
- Jiang Wentao, Bu Yifan. Image denoising network fusing with CNN and Transformer[J]. Computer Systems & Applications, 2024, 33(7): 39–51.
- [12] 党忆涵, 徐传芳, 王绍祖. 牵引整流器谐振电感短路故障诊断与容错控制[J]. 电气传动, 2025, 55(11): 82–89.
- Dang Yihan, Xu Chuanfang, Wang Shaozu. Traction rectifier resonant inductance short circuit fault diagnosis and fault-tolerant control[J]. Electric Drive, 2025, 55(11): 82–89.

收稿日期: 2025-01-06

修改稿日期: 2025-08-28