

基于多电流特征形态组合模式挖掘的层冷辊电机故障诊断

马天雨¹, 刘思亚¹, 刘金平², 郑之伟¹, 李志鹏¹

(1. 湖南师范大学物理与电子科学学院, 湖南长沙 410006; 2. 湖南师范大学信息科学与工程学院, 湖南长沙 410006)

摘要: 针对人工点检层冷辊电机存在过度维修和故障漏报的问题, 本文提出一种基于多电流特征形态组合模式挖掘的故障诊断方法. 该方法选取与故障相关的六种关键电流特征, 计算各特征的上下分位数形成边界, 采用 Bayes-L-BFGS (Bayes Limited-memory Broyden-Fletcher-Goldfarb-Shanno) 算法自动拟合出各特征的边界形态; 针对形态样本少的问题, 本文提出一种用于形态识别的 SCNN (Spatial Convolutional Neural Network)-Transformer 模型. 通过训练 Siamese-CNN 准确识别边界形态, 并训练 Transformer 识别边界时序关系与形态变化程度, 融合两个模型的识别结果确定边界形态类型; 以边界形态类型作为基因片段, 采用遗传算法挖掘出不同故障对应的多电流特征形态组合模式, 形成用于故障类型匹配的形态组合模式库. 在某钢厂层冷辊电机上对本文方法进行在线验证, 准确率超过 90%, 无关键故障漏报与误报.

关键词: 电流特征; 形态识别; 形态组合; 故障诊断

基金项目: 国家自然科学基金面上项目 (No.61971188)

中图分类号: TP277

文献标识码: A

文章编号: 0372-2112(2023)04-0870-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211596

Fault Diagnosis of Laminar Cooling Roller Motor Based on Morphological Combination Patterns Mining of Multi-Current Features

MA Tian-yu¹, LIU Si-ya¹, LIU Jin-ping², ZHENG Zhi-wei¹, LI Zhi-peng¹

(1. School of Physics and Electronics, Hunan Normal University, Changsha, Hunan 410006, China;

2. College of Information Science and Engineering, Hunan Normal University, Changsha, Hunan 410006, China)

Abstract: Aiming at the problems of excessive maintenance and fault omission of laminar cooling roller motor in the manual inspection layer, this paper proposes a fault diagnosis method based on morphological combination patterns mining of multi-current features. This method selects six key current features related to the fault, calculates each upper and lower quantiles of the features to form the boundary, and the Bayes-L-BFGS (Bayes Limited-memory Broyden-Fletcher-Goldfarb-Shanno) algorithm is used to automatically fit the boundary morphology of each feature. For the problem of few morphological samples, a SCNN (Spatial Convolutional Neural Network)-Transformer model for morphological recognition is proposed. By training Siamese-CNN, the model accurately identifies the boundary morphology, and trains Transformer to identify the boundary timing relationship and the degree of morphological change, and combines the recognition results of the two models to determine the morphological type. The paper uses the morphological type as the gene segment, and the genetic algorithm is used to mine the morphological combination patterns of multi-current features corresponding to different faults. The fault morphological combination patterns is used to form a morphological combination patterns library for fault type matching. The proposed method is verified online on laminar cooling roller motors in a steel mill, and the accuracy rate exceeds 90% with no missing or false alarm of key faults.

Key words: current features; morphological recognition; morphological combination; fault diagnosis

Foundation Item(s): National Natural Science Foundation of China (No.61971188)

1 引言

热轧带钢是一种通过热轧方式生产的带材和板材,在工业过程中发挥着重要作用^[1-3].在带钢生产过程中,层冷段的层冷辊道主要负责将带钢从精轧机运送到卷取机,每根辊子都由电机带动旋转.由于运行环境恶劣,层冷辊电机经常出现各种故障^[4].这些故障不仅会影响带钢质量,还会导致非停事故,给企业带来巨大损失.

目前企业主要依靠专家知识建立机理模型诊断电机故障,但这需要大量的人工经验^[5].另外,专家一般都通过分析振动信号来诊断电机故障^[6].然而,振动传感器价格昂贵,维护难度大.而电流采集器安装在配电柜,维护方便,基于电流信号特征分析的方法为电机故障诊断提供了新的选择.

近年来,机器学习成为故障诊断领域的研究热点^[7].研究者使用支持向量机、随机森林、贝叶斯分类器和人工神经网络等机器学习模型对电机进行故障诊断^[8-11].然而这些基本模型难以挖掘复杂数据的高维特征^[12].作为机器学习的重要分支,深度学习在语音处理、图像识别和故障诊断等领域得到了快速发展^[13,14].深度学习方法可以自动挖掘大数据中故障相关的各种抽象特征,并集成故障分类自动获取诊断结果^[15],因而基于深度学习的故障诊断方法受到学术界和工业界的广泛重视.常用于故障诊断的深度学习模型有深度信念网络(DBF)、自动编码器(AE)、长短时记忆网络(LSTM)、生成对抗网络(GAN)和卷积神经网络(CNN)等^[16-20].一些研究者开始将电流信号绘图输入二维卷积神经网络(2DCNN)识别故障形态.Lee等人^[21]基于2DCNN识别异常形态诊断电机故障.然而,2DCNN只能提取局部空间特征,无法捕捉时序内部间的关系特征.

针对CNN类方法难以挖掘时序关系特征的问题,Xiang等^[22]使用CNN-LSTM结构提取电流信号的时空特征来诊断电机故障.但在工程应用中,只能将故障时序依次输入LSTM,诊断速度缓慢并且关注重要特征.最近,Transformer基于多头注意力结构不仅能并行计算时序数据,获取长距离时序的关联特征,还能选择性地关注故障相关特征,大大提高了诊断效率.邱大伟等人^[23]基于前后特征矩阵,输入错误样本增强的Transformer得到故障诊断结果.

以上方法均需要大量样本才能训练高精度模型.然而,由于工作条件复杂和故障周期长,工业设备真实故障样本稀少,因此小样本故障诊断方法已成为研究热点.Zhang等人^[24]率先使用Siamese-CNN模型诊断故障,并取得了良好的效果.然而,Siamese-CNN仅能提取空间特征,不能挖掘时序内部关系;而Transformer能学习高维时序关系特征,但会忽略一些局部空间特征,且存在故障误漏报现象.为此,本文提出一种基于电流特征数据,采用

Siamese-CNN空间形态识别与Transformer时间序列关系识别相融合的电机故障诊断方法.故障诊断流程如图1所示,使用信号采集器采集的电流信号通过网络接口传输给服务器存储,服务器程序基于采样数据通过频谱和统计分析计算电流的故障特征信号,并选择与故障最相关的电流特征输入深度学习模型完成故障诊断及分类.主要创新点总结如下:(1)选择与故障相关的电流特征信号,计算特征信号的上下边界时序数据,采用基于Bayes-L-BFGS优化的拟合方法对边界时序数据进行拟合获取边界形态;(2)针对边界形态样本较少的问题,提出一种基于小样本形态识别模型,通过对Siamese-CNN识别的包络形态与Transformer识别的时序关系及变化程度进行决策融合,进而准确地判断各电流特征的边界形态类型;(3)采用遗传算法寻优不同故障类型对应的电流特征形态组合模式,通过组合模式的匹配在线识别电机故障类型,完成对所有关键故障的诊断及分类.

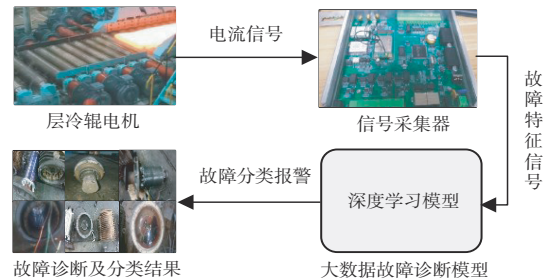


图1 热轧2050产线层冷辊道电机大数据故障诊断流程图

2 工艺说明

在钢铁热轧产线中,加热的钢坯依此经过粗轧、除鳞和精轧,再输入层冷段使用层流喷水对带钢降温,并通过层冷辊道运送带钢到卷取机以卷取成品.

层冷段在对带钢进行喷水冷却时,伴随着大量水汽进入的层冷辊电机,并且由于电机经常负载突变、变频调速,还有钢渣容易掉落进入电机,导致电机频繁发生各种故障.现场层冷辊电机发生次数较多的故障类型分别是电机接地、轴承卡阻、螺栓松动和联轴器不良,部分故障对应的电机电流特征信号图如图2所示.图2(a)电机接地故障发生时,ih3(电流三次谐波)和ineg(逆相序电流)出现明显的上边界阶跃,图2(b)螺栓松动故障发生时,ih2(电流二次谐波)和ih3(电流三次谐波)出现不同程度的上边界劣化.因此,可以通过分析不同电流特征的边界形态组合区分故障.

3 基于多电流特征形态组合模式挖掘的故障诊断

基于多电流特征形态组合模式挖掘的层冷辊电机故障诊断框架如图3所示,首先采集电机定子电流信号,

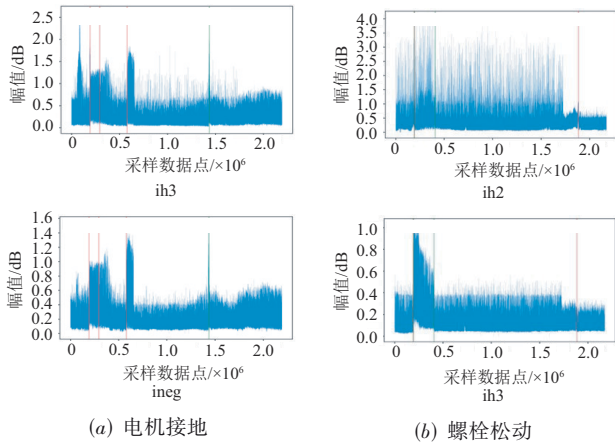


图2 电机电流信号特征图

选取能代表电机故障的关键电流特征,再提取各电流特征的95、05分位数,形成电流特征的边界形态;并采用Bayes-L-BFGS算法自动拟合出各特征的上下光滑边界,形成包络形态;针对形态样本少的问题,提出一种用于形态识别的SCNN-Transformer融合模型,通过训练Siamese-CNN准确识别包络形态、并训练Transformer识别时序关系及变化程度,融合两个模型的识别结果确定边界形态类型;最后根据故障记录表,建立以最小漏报率和误报率为目标、以各电流特征的形态类型作为基因片段、采用遗传算法挖掘故障组合模式的组合优化模型,得到包括电机接地、轴承卡组、螺栓松动和联轴器不良等故障的形态组合模式库,对在线电流信号从模式库中以模式匹配的方法识别故障类型。

3.1 电流特征形态提取

从数据采集器采样的三相电流数据中提取各种电流特征,再进行故障相关性分析、粗糙集属性约简和最终的现场专家筛选确认,获取各类故障相关的电流初始特征。基于故障台账和电流初始特征,建立初步的故障决策表,并采用式(1)离散化各类电流特征:

$$\delta = (z_{\max} - z_{\min}) / k \quad (1)$$

以电流二次谐波为例: z_{\max} 、 z_{\min} 表示电流特征的最大频谱值与最小频谱值, k 代表划分区间数。选取粗糙集分辨矩阵中故障发生时出现频率高且变化属性组合较短的特征,并采用循环删除法对属性重要性进行排序,选择前90%属性作为关键特征。最后筛选出与故障相关的六种关键电流特征,包括电流二次谐波(ih2)、电流三次谐波(ih3)、最大电流(imax)、转频二次谐波(mh2)、转频三次谐波(mh3)和逆相序电流(ineg)。其中,将每次采样的电流信号数据进行快速傅里叶变换,计算每次采样数据基电流频率的二倍频、三倍频频谱值,经连续采样获取ih2和ih3;计算电流原始数据每5秒内的最大值,获取imax;先对电流数据做解调获取调制波形数据,再对调制波形数据做FFT变换,提取最大电流谐波分量对应的频率,乘以频率分辨率得到转频谐波的转动频率(转频基频),获取转频二倍频以及三倍频处的频谱值,得到mh2与mh3;最后计算2、5、8、11、15次电流谐波频谱累加值,获取逆序电流ineg。计算各电流特征数据的一小时95分位数与05分位数,提取信号的上下边界数据,拼接为一个二维形态时序数组作为Transformer的时间序列输入。为了获得光滑的边界空间形态,需要对边界数据进行拟合。

采用Bayes-L-BFGS算法分段拟合边界数据以提取边界形态。首先采用式(2)所示的多分段拟合函数,对任意单边边界数据 $x \in R^{1 \times l}$ (l 为数据点个数)进行分段拟合。

$$\hat{x} = \begin{cases} k_1 + k_2(t - b_1), b_1 \leq t \leq b_2 \\ k_1 + k_2(t - b_1) + k_3(t - b_2), b_2 \leq t \leq b_3 \\ \vdots \\ k_1 + k_2(t - b_1) + \dots + k_{n_b}(t - b_{n_b-1}), b_{n_b-1} \leq t \leq b_{n_b} \end{cases} \quad (2)$$

其中, n 表示所有断点个数的可能取值, $n = 1, 2, \dots, n_b$; B 表示所有断点位置的横坐标, $B = b_2, b_3, \dots, b_{n_b-1}$ 。转换成矩阵表达式为

$$\hat{x}^T = Ak \quad (3)$$




图3 基于多电流特征形态组合模式挖掘的层冷辊电机故障诊断框架图

其中, $\hat{\mathbf{x}}^T = [x_1, x_2, \dots, x_h]^T$, h 表示分段数, $\mathbf{A} \in h \times n_b$ 为分段回归矩阵

$$\mathbf{A} = \begin{bmatrix} 1 & t_1 - b_1 & 0 & \dots & 0 \\ 1 & t_2 - b_1 & t_2 - b_2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & t_n - b_1 & t_n - b_2 & \dots & t_n - b_{n_b - 1} \end{bmatrix}$$

$\mathbf{k} = [k_1, k_2, \dots, k_{n_b}]^T$, $\mathbf{k} \in R^{1 \times n_b}$, \mathbf{k} 表示斜率差值向量, 为待优化参数. 采用最小二乘残差平方和函数作为优化目标:

$$SSR = (\mathbf{A}\mathbf{k} - \mathbf{x})^T (\mathbf{A}\mathbf{k} - \mathbf{x}) \quad (4)$$

式(4)为确定损失函数 SSR 关于断点个数 N 的函数表达式, 使用 Bayes 优化算法获取使损失函数最小的断点个数 n^* , $n^* \in n$, 再采用运行速度快的 L-BFGS 算法确定全局最优的断点位置组合 B^* , $B^* \subseteq B$, 最后使用最小二乘法对每一段进行线性回归, 获得全局最优的斜率差值向量 $\mathbf{k} \in R^{1 \times n_b}$, 其中 $\mathbf{k}^* = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{x}$, 确定最优的分段拟合函数. 上下边界数据分段拟合函数绘图即为光滑的包络形态图像, 作为 Siamese-CNN 的空间形态输入.

3.2 电流特征形态识别

电流特征形态识别框架如图 4 所示, 将包络形态图像输入 Siamese-CNN 识别边界空间形态, 将时序形态数组输入 Transformer 识别时序关系类型及故障程度, 融合两个模型的输出结果获得各电流特征的形态类型.

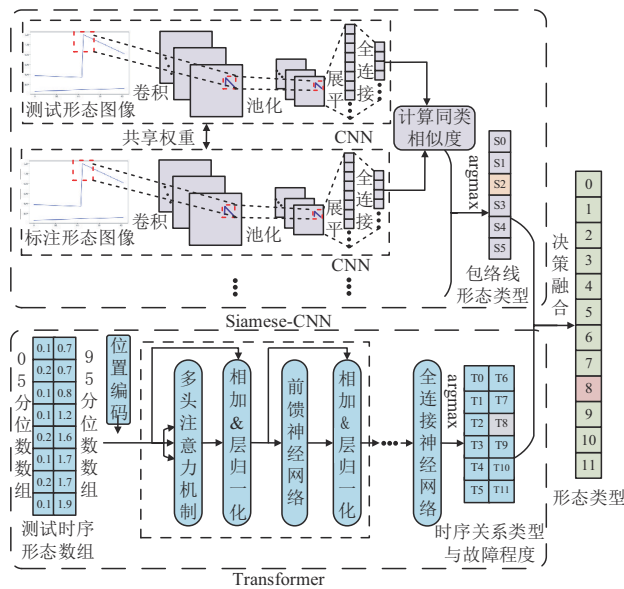


图 4 电流特征形态类型识别框架图

3.2.1 Siamese-CNN 识别包络形态

由于边界形态图像由简单线条组成, 使用一层含有少量卷积核的卷积层即可提取其空间特征. 选用 Triplet 三元训练模式, 随机循环选择三张形态图像组成

模型训练样本集 $\{x_A^i, x_P^i, x_N^i\}$, 其中, x_A^i 和 x_P^i 属于同一形态类型, x_A^i 和 x_N^i 属于不同形态类型; 训练样本经过卷积层提取的特征向量分别为 $f(x_A^i), f(x_P^i), f(x_N^i)$, 计算公式为

$$f(x) = \text{Flatten}(\text{ReLU}(\mathbf{W}_c * \mathbf{x} + b_c)) \quad (5)$$

采用标准的 Triplet 损失函数:

$$J(x_A^i, x_P^i, x_N^i) = \sum_{i=1}^M \max(\|f(x_A^i) - f(x_P^i)\|^2 - \|f(x_A^i) - f(x_N^i)\|^2 + \alpha, 0) \quad (6)$$

其中, M 表示形态类型总数, 当 $\{x_A^i, x_N^i\}$ 和 $\{x_A^i, x_P^i\}$ 的特征距离差大于边界 α 时, 损失函数 J 取 0, 反之取 $\|f(x_A^i) - f(x_P^i)\|^2 - \|f(x_A^i) - f(x_N^i)\|^2 + \alpha$, 当所有 Triplet 样本的特征距离差大于边界 α 时, 训练结束. 使用模型识别形态类型时, 提出一种如式(7)所示的相似度概率计算公式, 选择最大的概率 $P_S(K)_{\max}$ 所对应的形态类型作为 Siamese-CNN 的形态识别结果:

$$P_S(K) = 1 - \frac{\sum_{i=1}^N \|f(x_{\text{test}}) - f(x_i^K)\|^2}{\sum_{j=1}^C \sum_{i=1}^N \|f(x_{\text{test}}) - f(x_i^j)\|^2} \quad (7)$$

其中, x_{test} 表示测试样本, C 为所有形态的总类数, N 为每类形样本总数, x_i^K, x_i^j 分别表示 K, j 类形态样本.

3.2.2 Transformer 识别时序关系及形态变化程度

采用 Transformer 模型基于特征时序数据识别异常形态类型, 并区分故障严重程度. 为保留形态时序数据间的相对位置信息, 提出一种时间序列位置信息嵌入方法, 位置编码数组 E 中元素 $e_{i,j}$ 表达式如式(8)所示:

$$e_{i,j} = \frac{(i-1)n + j - 1}{2n - 1}, i = 1, 2; j = 1, 2, \dots, n \quad (8)$$

将 E 与形态时序数组 S 对应元素相加获得带位置信息的数组 $X = E + S$, 其中 S 表示上下分位数二维数组, 由 95 分位数数组和 05 分位数数组组成, n 表示分位数数组的长度. 将 X 进行线性变换获取注意力模块的查询 $Q = W^Q X$ 、键 $K = W^K X$ 和值 $V = W^V X$, 其中, W^Q, W^K 和 W^V 是 Q, K 和 V 对应的参数矩阵. 采用注意力计算公式:

$$\text{Att}(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (9)$$

拼接每个注意力头的校准后特征, 得到多头注意力 Multihead (Q, K, V) , 对多头注意力的输出进行残差连接和层归一化, 得到注意力加权重新校准后的输出:

$$\mathbf{X}_{\text{Att}} = \text{LayerNorm}(\mathbf{X} + \text{Multihead}(Q, K, V)) \quad (10)$$

其中, LayerNorm() 表示层归一化函数. 经过两层 1×1 卷积层后的输出再次与 \mathbf{X}_{Att} 进行残差连接与层归一化, 得到输出 \mathbf{X}_{conv} . 经过 N 层多头注意力模块加前馈神经

网络的输出向量为 X^N , 再输入全连接层计算 softmax 概率, 选择最大概率 $P_T(K)_{\max}$ 对应的形态作为测试样本的形态.

3.2.3 模型融合

采用一种决策级融合的方法融合 Siamese-CNN 和 Transformer 的输出获得最终的形态识别结果 K_{output} :

$$K_{\text{output}} = \begin{cases} K_T, K_S, K_T \in \text{Faults}, \\ K_S = K_T \\ K_S, K_S, K_T \in \text{Faults}, \\ K_S \neq K_T, P_T(K)_{\max} \leq T_h \\ K_T, K_S, K_T \in \text{Faults}, \\ K_S \neq K_T, P_T(K)_{\max} > T_h, \\ P_S(K)_{\max} < P_T(K)_{\max} \\ K_S, K_S, K_T \in \text{Faults}, \\ K_S \neq K_T, P_T(K)_{\max} > T_h, \\ P_S(K)_{\max} \geq P_T(K)_{\max} \\ K_S, K_S \in \text{Faults}, K_T \in \text{Normal}, \\ \text{Retrain} \\ K_T, K_S \in \text{Normal}, \\ K_T \in \text{Pseudo_Faults} \end{cases} \quad (11)$$

其中, K_S, K_T 分别表示 Siamese-CNN、Transformer 的形态识别结果, T_h 表示 Transformer 输出最大概率的阈值, Normal, Faults 分别表示正常形态、异常形态集合, 正常形态为双边界平稳, 异常形态集合为 {双边界上阶跃, 双边界下阶跃, 双边界劣化, 上边界阶跃, 上边界劣化}, Pseudo_Faults 表示伪异常形态集合且与 Faults 相同, $K_S = K_T, K_S \neq K_T$ 分别表示模型识别结果是否属于同一类型, Retrain 表示重新训练模型. 首先将 Transformer 输出同一形态不同程度归为一种形态, 则两种模型都具有 6 种形态. 若两个模型识别结果为同一形态则以 Transformer 输出为准; 若两个模型识别的异常形态不同, 且 $P_T(K)_{\max}$ 小于等于阈值, 则以 Siamese-CNN 输出为准; 若两个模型识别的异常形态不同, $P_T(K)_{\max}$ 大于阈值且 $P_S(K)_{\max}$ 小于 $P_T(K)_{\max}$, 则以 Transformer 的输出为准; 若两个模型识别的异常形态不同, $P_T(K)_{\max}$ 大于阈值且 $P_S(K)_{\max}$ 大于等于 $P_T(K)_{\max}$, 则以 Siamese-CNN 的输出为准; 若 Siamese-CNN 和 Transformer 识别的分别是异常与正常形态, 表示 Transformer 漏报, 应重新训练好 Transformer 后, 再根据上述条件判断异常形态类型; 若 Siamese-CNN 和 Transformer 分别识别的是正常和异常形态, 表示 Transformer 误报, 应以 Siamese-CNN 识别的形态类型为准. 识别出形态后, 根据 Transformer 的初始输出进一步判断形态的变化程度 (注意或异常), 获取最终的形态识别结果.

3.3 多电流特征形态组合模式挖掘

每种电流特征都可能出现 6 种形态中的一种, 需要

从中筛选出故障对应的电流特征形态组合. 多电流特征形态组合模式挖掘过程如图 5 所示. 在组合优化中, 只考虑识别为异常情况的 6 种形态, 并以数字代表形态类型: 双边界上阶跃 (DBUS)、双边界下阶跃 (DBLS)、上边界阶跃 (UBUS)、双边界劣化 (DBD)、上边界劣化 (UBD)、双边界平稳 (DBS) 分别用 0、1、2、3、4、5 数字表示. 形态在基因片段中所处的位置代表不同的电流特征, 各特征在基因片段中的排列顺序为 [ih2, ih3, imax, mh2, mh3, ineg]. 对每个电流特征 24 小时的窗口数据, 提取每个窗口数据一小时的 95、05 分位数并拟合边界形态, 使用 SCNN-Transformer 模型识别各电流特征的窗口数据边界形态, 采用遗传算法挖掘各特征在不同故障类型下的形态组合模式.

随机初始化基因片段种群, 经过交叉变异后产生新的子代种群, 将子代种群的基因片段与各故障标记形态组合对应位置的形态组合值逐一相减, 获得形态差值表, 再提取差值表中值为 0 的位置 (电流特征) 和形态值 (形态类型), 得到形态位置组合表, 计算过程如式 (12) 所示:

$$\begin{bmatrix} g_1^1 & g_1^2 & \cdots & g_1^6 \\ g_2^1 & g_2^2 & \cdots & g_2^6 \\ \cdots & \cdots & \cdots & \cdots \\ g_m^1 & g_m^2 & \cdots & g_m^6 \end{bmatrix} - \begin{bmatrix} l_1^1 & l_1^2 & \cdots & l_1^6 \\ l_2^1 & l_2^2 & \cdots & l_2^6 \\ \cdots & \cdots & \cdots & \cdots \\ l_n^1 & l_n^2 & \cdots & l_n^6 \end{bmatrix} = \begin{bmatrix} 0 & - & \cdots & - \\ 0 & - & \cdots & - \\ \cdots & \cdots & \cdots & \cdots \\ 0 & 0 & \cdots & - \end{bmatrix} \Rightarrow \begin{bmatrix} 1 & 3 & - & 2 & 3 \\ 1 & 3 & - & 2 & 3 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & 2 & 4 & - & 2 & 3 & 4 \end{bmatrix} \quad (12)$$

其中, $\{g_i^1, g_i^2, \cdots, g_i^6\}, \{l_i^1, l_i^2, \cdots, l_i^6\}$ 分别表示子代种群中的基因片段与故障标记形态组合, m, n 分别表示初始种群个体数目和一类标记故障形态组合样本数, 形态位置组合表中每行前半部分是形态位置组合, 后半部分是对应形态. 统计各故障下的各形态位置组合出现的频次, 得到矩阵:

$$F = \begin{bmatrix} f_1^1 & f_2^1 & \cdots & f_k^1 \\ f_1^2 & f_2^2 & \cdots & f_k^2 \\ \cdots & \cdots & \cdots & \cdots \\ f_1^n & f_2^n & \cdots & f_k^n \end{bmatrix} \quad (13)$$

其中, f_j^i 表示 i 类故障发生时的 j 种形态位置组合出现的频次. 计算每一故障下所有形态位置组合出现的总频次向量 $N = [n^1, n^2, \cdots, n^n]^T$, 再计算每一故障下任意一种形态位置组合出现的频率矩阵:

$$D = F/N = \begin{bmatrix} d_1^1 & d_2^1 & \cdots & d_k^1 \\ d_1^2 & d_2^2 & \cdots & d_k^2 \\ \cdots & \cdots & \cdots & \cdots \\ d_1^n & d_2^n & \cdots & d_k^n \end{bmatrix} \quad (14)$$

选择每个故障中 d 值最大的 t 种形态组合计算故障误报

率、漏报率与故障分类错误率之和 R , 表达式为

$$R = \frac{P_{f_num} - L_{f_num}}{L_{f_num}} + \frac{L_{f_num} - U_{f_num}}{L_{f_num}} + \sum_{i=1}^n \frac{U_{f_num}^i - C^i}{U_{f_num}^i} \quad (15)$$

其中, P_{f_num} 、 L_{f_num} 分别表示模型故障次数、标签故障次数; U_{f_num} 表示模型正确报警故障次数, 而 $U_{f_num}^i$ 代表第 i 类模型的故障正确报警次数; C^i 表示正确分类次数. 每一轮迭代都选择种群中 d 值最大的前 50% 基因组合, 加入随机产生 50% 新种群, 进入下一轮迭代, 当 R 值小于某一个阈值时优化结束, 获得最优的故障形态组合模式.

4 实验验证

4.1 过程介绍及参数设置

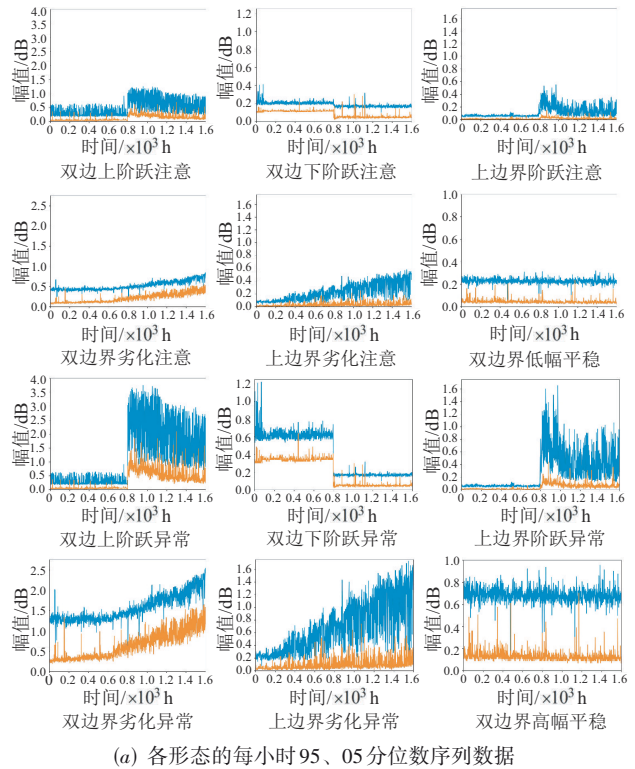
实验平台为 NVIDIA GTX2080S GPU, 16 GB RAM 的计算机, 使用 Keras2.2.5 深度学习框架训练模型. 采集某钢铁厂热轧 2050 产线的 39 台层冷辊电机从 2018 年 6 月到 2020 年 6 月的定子电流数据, 采样频率为 10 kHz, 每 5 秒计算一次 6 种关键电流特征的数据, 绘制其图形. 截取在故障发生前后约一个月 (共两个月) 的存在异常形态的电流特征数据, 计算每小时的 95、05 分位数, 序列数据绘图如图 5(a) 所示. 以 720 个点为窗口宽度, 每隔 5 个点从特征序列数据中滑动截取 160 个形态样本, 将 95、05 特征序列拼接为 $[720, 2]$ 的二维数组, 并对 12 种形态打上 0 到 11 的标签, 形成二维形态样本. 按照 5:2:3 的比例将所有的划分为训练集、验证集和测试集.

以二维形态样本训练的 Transformer 由 4 个连续的多头注意力-前馈神经网络模块、两层全连接神经网络组成, 多头注意力头数为 8, 大小为 64, 前馈神经网络由三层包含 1×1 卷积核的卷积层构成, 核数分别为 128、192、2, 全连接层的神经元数为 128、12. 目标函数为稀疏交叉熵损失函数, batch_size 和 epoch 分别为 16 和 500.


使用 Bayes-L-BFGS 算法对 12 种二维形态进行拟合, 忽视幅值高低根据形态变化合并为 6 类, 形成 6 类边界形态, 每类图像样本由原来的 160 个扩展为 320 个, 作为 Siamese-CNN 的输入, 每张形态包络线图像大小为 $(64, 64)$. Siamese-CNN 模型的每个 CNN 由一层卷积层组成, 卷积层中有 16 个 7×7 的卷积核. 目标函数选择三重损失函数, batch_size 和 epoch 分别为 16 和 500.

4.2 性能对比

比较使用不同 batch_size、epoch 超参数的 SCNN-Transformer 形态识别准确率, 如表 1 所示, 结果发现 batch_size 选取 16 与 epoch 选取 500 时形态识别准确率最高. 使用 10 折交叉验证方法测试 GRU、LSTM、Trans (Transformer)、S-G (SCNN-GRU)、S-L (SCNN-LSTM) 和



(a) 各形态的每小时 95、05 分位数序列数据



(b) 序列数据拟合边界

图 5 边界形态图

S-T (SCNN-Transformer) 这 6 种深度学习模型的性能, 其中 GRU 和 LSTM 分别由两层 64 单元的 GRU 层和 LSTM 层构成, S-G、S-L 和 S-T 分别表示 Siamese-CNN 与 GRU、Siamese-CNN 与 LSTM、Siamese-CNN 与 Transformer 的混合模型, 混合模型为上述单个结构模型的并联. 以对 12 类形态测试集的分类准确率作为评价指标, 10 折交叉验证的测试结果如表 2 所示. 可以看出在单模型运行结果中 Transformer 在测试形态数据集上表现最好, 识别准确率提高了 5% 以上, 这说明 Transformer 在处理长序列提取相关特征上比传统的 RNN 模型效果更好; 但混合模型比单模型效果更好, 其中 SCNN-Transformer 取得了最高的测试准确率, 这说明本文所提模型在本论文数据集中表现最好. 另外, 各类模型的训练迭代速度

不同,比较线性模型和其他模型的迭代速度,具体数值如表3所示.可以发现,线性模型的运行速度最快,而深度学习模型随着网络模块的增加,迭代速度逐渐下降,但SCNN-Transformer在牺牲部分速度的情况下仍能满足现场需求,且精度最高.

选取SCNN-Transformer测试结果最好的模型绘制如图6所示的混淆矩阵,可见SCNN-Transformer模型基本可以预测正确每一类形态类型,满足现场的形态识别要求.另外,对该模型的最后一层输出进行T-SNE可视化,结果如图7所示,可以看出12种边界形态的清晰界限,证明SCNN-Transformer学习到了本文形态的区分特征.

对SCNN-Transformer识别出的各电流特征的异常形态,基于历史故障形态组合模式记录表,采用遗传算法挖掘不同故障的最优形态组合模式库.初始种群取1000个体,每个个体有6个基因片段,每个基因片段的位置表示6种电流特征,基因片段的值代表不同类型的边界形态.遗传算法迭代不同轮数对应的故障诊断准确率结果如表4所示,结果显示当迭代500轮时,诊断效果最好.取最好的一次优化结果,挖掘出各形态组合模式库中一种典型的最优形态组合模式如表5所示.以SCNN-Transformer识别的形态作为输入,在组合模式

表4 遗传算法迭代轮数对应的故障诊断准确率结果表

迭代轮数	100	200	300	400	500	600
准确率/%	23.63	52.62	66.54	89.25	98.33	98.06

表5 各类故障对应形态组合模式表

故障类型	ih2	ih3	imax	mh2	mh3	ineg
电机接地	DBUS	UBD	DBS	UBUS	UBUS	DBDS
轴承卡阻	DBD	DBD	UBD	UBUS	UBUS	DBUS
螺栓松动	UBUS	UBD	DBS	DBS	DBS	UBUS
联轴器不良	UBUS	UBD	DBS	UBD	UBD	UBD




图6 SCNN-Transformer混淆矩阵图




图7 SCNN-Transformer的T-SNE特征可视化图

库中以模板匹配的方式实现故障在线分类诊断.统计从18年1月到20年6月的所有具有明显数据异常的典型故障进行离线测试,模型报警漏报率为0,而误报率为11.6%,故障分类错误率为1.72%,R值为13.32%,满足现场故障诊断低于15%的要求.

比较傅里叶分析(FFT)、小波分析(WT)、经验模态分析(EMD)与所提方法的故障诊断准确率,如表6所示,本文方法准确率最高.这表明本文的特征提取方法能更加准确地提取真正导致故障的核心特征,而这种特征难以被信号处理方法所挖掘.

本文方法在其他工厂的层冷辊电机也做了相同的

表1 不同超参数对应模型的形态识别准确率结果表 单位:%

epoch	batch_size		
	8	16	32
100	63.67	67.89	62.36
200	72.67	73.58	72.61
300	88.63	90.23	89.67
400	98.34	98.86	97.78
500	98.33	99.17	98.89

表2 各模型形态识别准确率测试结果 单位:%

测试	GRU	LSTM	Trans	S-G	S-L	S-T
测试1	89.79	87.38	93.13	94.17	88.13	97.71
测试2	88.33	86.89	97.29	91.26	91.26	98.75
测试3	88.75	89.81	93.54	93.20	89.58	97.51
测试4	88.54	87.38	92.50	90.83	90.29	98.76
测试5	88.83	88.35	93.96	92.71	89.32	98.34
测试6	91.04	88.83	96.46	91.26	90.78	97.93
测试7	93.75	90.29	95.83	91.75	91.25	99.17
测试8	88.35	87.86	91.25	90.78	88.33	98.33
测试9	90.29	86.04	92.92	94.66	91.75	98.96
测试10	89.25	86.71	96.67	90.29	89.32	97.29
平均值	89.69	87.95	94.31	92.09	90.00	98.28

表3 各类模型迭代时间表

模型	PCA	GRU	LSTM	Trans	S-G	S-L	S-T
迭代时间/s	66	226	276	246	445	526	513

表6 传统信号处理方法与本文方法的故障诊断对比结果

方法	FFT	WT	EMD	本文方法
准确率/%	73.22	82.36	86.62	98.33

验证实验,能满足现场的故障诊断要求;另外,该方法在大型的高压电机上也对电机本体故障进行了验证实验,能精确分类定转子不对齐故障、转子不平衡等渐进性劣化故障;该方法还有待于在其他应用场景,如轧机、水泵等电机带动的设备等多种实际工序中验证其实用性,在验证过程中对该方法继续优化改进;后续也会在标准电流故障数据集中验证该方法的有效性,还可以考虑在该框架中加入域自适应方法以提高未经训练场景下模型的泛化能力。

5 结论

本文提出了一种基于多电流特征形态组合模式挖掘的电机故障诊断方法。选择电 6 种关键电流特征,采用 SCNN-Transformer 识别各特征的边界形态,并使用遗传算法寻优不同故障类型对应的形态组合模式。经过现场验证,本文提出的方法能对各种已知电机故障进行预警,并符合现场的最低误报漏报要求。但本文方法还存在对掉渣、短路和粘铁等异常工况的少量误报警,后续可考虑将异常工况纳入形态识别,进一步降低误报率。

参考文献

- [1] 郑昌琼. 简明材料词典[Z]. 北京: 科学出版社, 2002: 311. ZHENG Changqiong. Concise Material Dictionary[Z]. Beijing: Science Press, 2002: 311. (in Chinese)
- [2] 那宝魁. 钢铁企业标准化管理体系[M]. 北京: 冶金工业出版社, 2015:106. NA Baokui. Standardized Management System of Iron and Steel Enterprises[M]. Beijing: Metallurgical Industry Press, 2015: 106. (in Chinese)
- [3] 刘金平, 王杰, 唐朝晖, 等. 基于自适应滑窗递归稀疏主成分分析的工业过程故障监测[J]. 电子学报, 2020, 48(9): 1795-1803. LIU Jinping, WANG Jie, TANG Chaohui, et al. Industrial process fault monitoring based on adaptive sliding window-recursive sparse principal component analysis[J]. Acta Electronica Sinica, 2020, 48(9): 1795-1803.(in Chinese)
- [4] 沈政. 热轧层冷电机负载电流在线监控技术及其应用[J]. 科技经济市场, 2020, 11(6): 18-20. SHEN Zheng. Online monitoring technology of load current of layer cooling motor in hot rolling and its application [J]. Science, Technology and Economic Market, 2020, 11(6): 18-20. (in Chinese)
- [5] 董云飞. 基于知识的电动机故障诊断专家系统[J]. 中国科技博览, 2014, 16(10): 277. DONG Yunfei. Motor fault diagnosis expert system based on knowledge[J]. China Science and Technology Expo, 2014, 16(10): 277. (in Chinese)
- [6] 蔡少辉. 基于振动信号分析的电机故障诊断应用研究[J]. 电子测试, 2021, 23(6): 95-96. CAI Shaohui. Application research of motor fault diagnosis based on vibration signal analysis[J]. Electronic Testing, 2021, 23(6): 95-96. (in Chinese)
- [7] KUMAR P, HATI A S. Review on machine learning algorithm based fault detection in induction motors[J]. Archives of Computational Methods in Engineering, 2021, 28(3): 1929-1940.
- [8] 赵慧敏. 基于智能优化方法的SVM电机故障诊断模型研究[J]. 大连交通大学学报, 2016, 37(1): 92-96. ZHAO Huimin. Research on motor fault diagnosis model for support vector machine based on intelligent optimization methods[J]. Journal of Dalian Jiaotong University, 2016, 37(1): 92-96. (in Chinese)
- [9] 王训训, 陈天, 刘正杰, 等. 粒子群优化融合随机森林的电机故障诊断方法[J]. 微特电机, 2019, 47(10): 42-45. WANG Xunxun, CHEN Tian, LIU Zhengjie, et al. Motor fault diagnosis method based on particle swarm optimization and random forest [J]. Small & Special Electrical Machines, 2019, 47(10): 42-45. (in Chinese)
- [10] 谢丰, 付文鹏, 李阳, 等. 基于贝叶斯决策模型的热轧卷筒电机故障诊断[J]. 中国冶金, 2021, 31(4): 68-73. XIE F, FU W P, LI Y, et al. Fault diagnosis of reel motor in hot continuous rolling based on Bayesian decision[J]. China Metallurgy, 2021, 31(4): 68-73. (in Chinese)
- [11] 张行, 朱树先. 改进的神经网络分类法在异步电机故障诊断中的应用[J]. 自动化与仪器仪表, 2018, (4): 214-218. ZHANG X, ZHU S X. Improved neural network classification method used in fault diagnosis of asynchronous motor[J]. Automation & Instrumentation, 2018,(4): 214-218. (in Chinese)
- [12] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187. DING S C, LI X Y, HANG J, et al. Deep learning theory and its application to fault diagnosis of an electric machine[J]. Power System Protection and Control, 2020, 48(8): 172-187. (in Chinese)
- [13] 孙文君. 基于深度学习模型的感应电机故障诊断方法

研究[D]. 南京: 东南大学, 2017: 4-5.

SUN W J. Induction Motor Fault Diagnosis Based on Deep Learning Models[D]. Nanjing: Southeast University, 2017: 4-5. (in Chinese)

- [14] JIANG W, WANG C, et al. Application of deep learning in fault diagnosis of rotating machinery[J]. Processes, 2021, 9(6): 919.
- [15] SHAO S Y, SUN W J, YAN R Q, et al. A deep learning approach for fault diagnosis of induction motors in manufacturing[J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1347-1356.
- [16] 郝鹏永. 基于深度信念网络的异步电机典型故障的诊断方法及其实验研究[D]. 秦皇岛: 燕山大学, 2019: 2-3. HAO Pengyong. Diagnosis Method and Experimental Research of Typical Faults of Asynchronous Motor Based on Deep Belief Network [D]. Qinhuangdao: Yanshan University, 2019: 2-3. (in Chinese)
- [17] WANG B, et al. Turn-to-turn short circuit of motor stator fault diagnosis in continuous state based on deep auto-encoder[J]. IET Electric Power Applications, 2019, 13(10): 1598-1606.
- [18] XIAO D Y, HUANG Y X, ZHANG X D, et al. Fault diagnosis of asynchronous motors based on LSTM neural network[C]//2018 Prognostics and System Health Management Conference (PHM-Chongqing). Piscataway: IEEE, 2018: 540-545.
- [19] SHAO S, WANG P, YAN R. Generative adversarial networks for data augmentation in machine fault diagnosis [J]. Computers in Industry, 2019, 106: 85-93.
- [20] JIAO J, ZHAO M, LIN J, et al. A comprehensive review on convolutional neural network in machine fault diagnosis[J]. Neurocomputing, 2020, 417: 36-63.
- [21] LEE J H, PACK J H, et al. Fault diagnosis of induction motor using convolutional neural network[J]. Applied Sciences, 2019, 9(15): 2950.
- [22] XIANG L, WANG P, YANG X, et al. Fault detection of wind turbine based on SCADA data analysis using CNN and LSTM with attention mechanism[J]. Measurement, 2021, 175(8): 109094.
- [23] 邱大伟, 刘子辰, 周一青, 等. 基于Transformer神经网络的滚动轴承故障类型识别[J]. 高技术通讯, 2021, 31(1): 1-11. QIU D W, LIU Z C, ZHOU Y Q, et al. A novel fault type detection method of rolling bearing using Transformer neural networks[J]. Chinese High Technology Letters, 2021, 31(1): 1-11. (in Chinese)


- [24] ZHANG A, LI S, CUI Y, et al. Limited data rolling bearing fault diagnosis with few-shot learning[J]. IEEE Access, 2019, 7: 110895-110904.

作者简介



马天雨 男, 1978年10月生, 甘肃白银人. 博士, 现为湖南师范大学电子系讲师、硕士生导师. 主要研究方向为基于大数据深度学习的工业过程智能化.

E-mail: mty@hunnu.edu.cn



刘思亚 男, 1998年5月生, 湖南衡东人. 湖南师范大学电子与通信工程专业硕士. 主要研究方向为基于深度学习的故障诊断.

E-mail: mty@hunnu.edu.cn



刘金平(通讯作者) 男, 1983年9月生, 湖南洞口人. 博士, 现为湖南师范大学信息科学与工程学院教授. 主要从事智能信息处理、过程监测、故障诊断等相关研究.

E-mail: ljp202518@163.com